

Ursachen- und wirkungsorientierte Analyse gesammelter Fahrprofile zur taktischen Fahrtoptimierung

Inaugural-Dissertation

zur

Erlangung des Doktorgrades der
Mathematisch-Naturwissenschaftlichen Fakultät
der Heinrich-Heine-Universität Düsseldorf

vorgelegt von

Markus Kerper

aus Hilden

Mai 2013

Aus dem Institut für Informatik
der Heinrich-Heine-Universität Düsseldorf

Gedruckt mit der Genehmigung der
Mathematisch-Naturwissenschaftlichen Fakultät der
Heinrich-Heine-Universität Düsseldorf

Referent: Prof. Dr. Martin Mauve
Heinrich-Heine-Universität Düsseldorf

Koreferent: Prof. Dr. Björn Scheuermann
Humboldt-Universität zu Berlin

Tag der mündlichen Prüfung: 19.07.2013

Zusammenfassung

Ein Fahrer, der das Ziel hat vorausschauend zu fahren, muss die für ihn fahrbare Maximalgeschwindigkeit auf der vorausliegenden Strecke abschätzen, um unnötige Beschleunigungs- und Bremsvorgänge zu vermeiden. Die fahrbare Maximalgeschwindigkeit auf einem Streckenabschnitt unterliegt diversen Beschränkungen, die u. a. aus Streckengeometrie, Verkehrszeichen und der Witterung resultieren. Die dieser Arbeit zugrunde liegende Beobachtung ist, dass Fahrer zum einen in komplexen Situationen und auf unbekanntem Streckenabschnitt aufgrund des Informationsdefizits nicht in der Lage sind die fahrbare Maximalgeschwindigkeit für die nächsten x-hundert Meter abzuschätzen. Zum anderen ist es für den Fahrer eine große Herausforderung fahrzeugspezifische verbrauchseffiziente Fahrmanöver daraufhin abzuleiten. Ein rechtzeitiges Ausrollen bei der Zufahrt auf ein Stoppschild erfordert z. B. das Abschätzen der Distanz zum Schild und des fahrzeugspezifischen Ausrollweges.

Diese Arbeit verfolgt das Ziel, dem Fahrer die oben genannten komplexen Aufgaben, d. h. die Berechnung der fahrbaren Maximalgeschwindigkeit und der daraus resultierenden verbrauchseffizienten Fahrmanöver, mittels eines Assistenzsystems abzunehmen. Der Beitrag dabei ist ein System zur Berechnung der fahrbaren Maximalgeschwindigkeit aus vergangenen und aktuellen Fahrprofilen. Dazu wird in dieser Arbeit die steigende Verfügbarkeit von Kommunikation zwischen Fahrzeugen und Servern ausgenutzt. Fahrzeuge sind dadurch in Zukunft beispielsweise in der Lage ihre Fahrprofile (Zeit, Geschwindigkeit, Ort) und andere Beobachtungen (wie Glätte und Regen) an einen Server zu senden. Die gesammelten Fahrprofile bilden die Grundlage der in dieser Arbeit entwickelten Verfahren. Ein Fahrprofil ist dabei immer das Resultat einer Fahrt, die durch eine Menge von beschränkenden Faktoren beeinflusst wird. Diese Einflussfaktoren sind baulicher Art (Streckengeometrie und Verkehrsschilder), tageszeitabhängig (Verkehrsfluss und Lichtverhältnis), entstehen durch Verkehrssteuerung (Vorfahrtsregeln und Lichtsignalanlagen) oder sind fahrer- bzw. fahrzeugspezifisch.

Die Vielfalt der Einflussfaktoren und die Beobachtung, dass alleine aus den Fahrprofilen nur schwierig auf die örtlich wirkenden Einflussfaktoren geschlossen werden kann, sind

der Grund für die Entwicklung zweier Verfahren zur Analyse der Fahrprofile auf einem Server: Die *wirkungsorientierte* und die *ursachenorientierte* Analyse. Die wirkungsorientierte Analyse wird eingesetzt für den Fall, dass der maßgebende Einflussfaktor an einem Ort unbekannt ist. Im Gegensatz dazu wird bei bekanntem, maßgebendem Einflussfaktor eine der Ursache angepasste Analyse der Fahrprofile durchgeführt. In dieser Arbeit werden drei Kernbeiträge beschrieben, dabei ist der erste Beitrag ein Algorithmus der wirkungsorientierten Analyse und die weiteren Kernbeiträge sind Algorithmen der ursachenorientierten Analyse.

Die wirkungsorientierte Analyse ist ein generischer Ansatz zur Analyse von Fahrprofilen, bei dem die Einflussfaktoren auf das Fahrprofil nicht speziell betrachtet werden, sondern ausschließlich deren Auswirkungen (d. h. das Resultat aller Einflüsse) analysiert werden. Die Idee dabei ist die fahrbare Maximalgeschwindigkeit auf dem vorausliegenden Streckenabschnitt durch den Geschwindigkeitsverlauf, den Fahrzeuge typischerweise dort fahren, aus historischen Fahrprofilen abzuschätzen. Dieser typische Verlauf entspricht dann der Geschwindigkeit, die der Fahrer ohne Unterstützung wahrscheinlich fahren würde. In bestimmten Situationen, wie z. B. bei „rechts vor links“, gibt es nicht nur einen typischen Geschwindigkeitsverlauf. Fahrer können anhalten oder auch mit leicht verminderter Geschwindigkeit weiterfahren.

Der erste Kernbeitrag dieser Arbeit ist ein Algorithmus zur Erkennung von *charakteristischen* Geschwindigkeitsverläufen und deren Wahrscheinlichkeit für jeden Streckenabschnitt. Dazu werden zunächst relevante Fahrprofile auf dem Server durch Filterung nach aktueller Tageszeit, Witterung und Fahrertyp identifiziert. Anschließend werden mittels Klassifizierung die charakteristischen Geschwindigkeitsverläufe aus der Menge der relevanten Fahrprofile erkannt, deren Wahrscheinlichkeiten berechnet und an das Fahrzeug übertragen. Das System im Fahrzeug verwendet diese Informationen daraufhin, um situationsabhängig die fahrbare Maximalgeschwindigkeit und verbrauchseffiziente Fahrmanöver zu berechnen. Das Problem bei der Klassifizierung von Fahrprofilen ist es ein Ähnlichkeitsmaß zu finden, welches die Verschiebung von Fahrprofilen zueinander berücksichtigt; beispielsweise halten Fahrzeuge an einem Stoppschild an unterschiedlichen Positionen bei Rückstau. In dieser Arbeit wird mit Dynamic Time Warping (DTW) ein Ähnlichkeitsmaß gewählt, welches bereits in der Spracherkennung eingesetzt wurde, um gleiche Wörter trotz unterschiedlich schneller Aussprache zu erkennen. Evaluert wird der Algorithmus mittels realer Fahrprofile. Ergänzend zu diesem Beitrag wird das Potenzial untersucht, den Kraftstoffverbrauch mittels eines solchen Systems mit Hilfe einer Kraftstoffverbrauchssimulation zu verringern.

Bei der ursachenorientierten Analyse wird im Vergleich zur wirkungsorientierten Analyse die Kenntnis über den maßgebenden Einflussfaktor genutzt. Innerorts werden Fahrprofile ganz wesentlich durch den Status von Lichtsignalanlagen (LSA) beeinflusst. Die Kenntnis über die Positionen von Kreuzungen und LSA kann z. B. aus einer digitalen Karte oder einer Verkehrszentrale bezogen werden. Die Idee in dieser Arbeit ist, durch Analyse von Fahrprofilen an durch LSA gesteuerten Kreuzungen, die Schaltzeiten zu schätzen (rückwärts zu rechnen) und die Korrelationen zwischen Schaltzeiten aufeinanderfolgender LSA (z. B. bei „grüner Welle“) zu bestimmen. Die beiden weiteren Kernbeiträge dieser Arbeit sind zwei Algorithmen zur ursachenorientierten Analyse von Fahrprofilen an LSA: Der erste Algorithmus wird an LSA, deren Schaltzeiten über einen längeren Zeitraum statisch sind, eingesetzt. Mit dem zweiten Algorithmus werden LSA adressiert, deren Schaltzeiten mit räumlich umliegenden LSA korreliert sind. Das heißt, dass die Schaltzeiten der LSA einer Kreuzung nicht statisch, die Schaltzeiten aufeinanderfolgender LSA zueinander aber statisch sein müssen. Beide Algorithmen ermöglichen die Bestimmung des Status der LSA bei Ankunft des Fahrzeugs und damit der fahrbaren Maximalgeschwindigkeit.

Der zweite Kernbeitrag dieser Arbeit ist TLSE (engl. Traffic Light State Estimation), ein System zum Lernen der LSA-Umschaltzeiten auf Basis von Fahrprofilen. Dazu werden „Beobachtungen“ aus Fahrprofilen über den LSA-Status über der Zeit extrahiert, die Umschaltzeiten in der Vergangenheit analysiert, um daraus auf die Parameter (Umlaufzeit und Länge der Grün- bzw. Rotphasen) zu schließen, welche die Schaltzeiten der LSA beschreiben. In dieser Arbeit werden diese Parameter als LSA-Parameter bezeichnet. Dies geschieht in zwei Schritten: Zuerst werden die LSA-Parameter einzelner Fahrrichtungen geschätzt und anschließend wird die Stabilität der Schätzungen erhöht, indem die Schätzungen der einzelnen Fahrrichtungen miteinander kombiniert werden. Mit Hilfe der Parameter lässt sich der Status der LSA zu jedem Zeitpunkt in der Zukunft (z. B. zum Ankunftszeitpunkt des Fahrzeugs) bestimmen. TLSE ist das erste System zum Schätzen der LSA-Parameter auf Basis von Fahrprofilen. Evaluiert wird der Algorithmus unter Verwendung einer Verkehrssimulation, in welcher unterschiedliche Steuerungsverfahren von Lichtsignalanlagen implementiert wurden. In der Simulationsumgebung erreichte der Algorithmus eine Genauigkeit von über 90% für Festzeitsteuerungen und 80% für verkehrsadaptive Steuerungen für LSA mit fester Umlaufzeit, wobei nur 5% der Fahrzeuge ihre Fahrprofile austauschen.

Der dritte Kernbeitrag dieser Arbeit ist ein Algorithmus zur Erkennung von Korrelationen zwischen LSA (TLCoRA (engl. Traffic Light Correlation Analysis)), um aus dem Geschwindigkeitsverlauf an der zurückliegenden LSA auf die fahrbare Maximalge-

schwindigkeit an der vorausliegenden LSA zu schließen. Hierbei ist die Idee, zunächst den relativen Zeitpunkt zum Phasenplan einer in der Vergangenheit passierten LSA zu berechnen. Unter der Annahme, dass dieser Phasenplan mit dem Phasenplan der vorausliegenden LSA korreliert ist, können aus der Menge aller Fahrprofile mit ähnlichem relativen Zeitpunkt zum Phasenplan charakteristische Geschwindigkeitsverläufe und deren Wahrscheinlichkeit berechnet werden. Zur Klassifikation von Geschwindigkeitsverläufen wird dabei erneut DTW genutzt. In Simulationsszenarien wird gezeigt, dass die Berechnung des relativen Zeitpunkts und die darauf basierenden charakteristischen Geschwindigkeitsverläufe geeignet sind, den zukünftigen Geschwindigkeitsverlauf vorherzusagen.

Abstract

Fuel-efficient driving has a huge impact on emission as well as on operating costs of a vehicle. Drivers predict the maximum speed for the next few hundred meters based on their knowledge and perception of road geometry, speed limits, traffic light signal phases and traffic conditions. Especially in unknown or complex environments, this prediction is difficult for the driver, as he often either lacks information or suffers information overload. In the next step the driver has to predict the most fuel-efficient driving style depending on the maximum speed and vehicle specific dynamics. A driver information system that makes such a prediction automatically is thus desirable.

In this work, we propose a novel system that performs the complex tasks to predict the maximum speed and most fuel-efficient driving style as mentioned above. Our main contribution are algorithms to predict the maximum speed based on *live* and *historical velocity profiles* that have been shared by inter-vehicle communication. Profiles can either be exchanged among vehicles in a decentralized way or stored and requested via a central server. Additionally those profiles contain information about rain, slippery or other sensor data of the vehicle if required. The proposed algorithms in this work rest upon gathered velocity profiles. In doing so one has to notice that a velocity profile is the result of a trip influenced by several factors limiting the driver's velocity. On the one hand the influencing factor can be static, like the geometry of the road or current speedlimit. On the other hand the factors can depend on the current time of day, like traffic flow and lighting conditions, or traffic control by traffic signs (e. g. stop sign) or traffic lights. Besides that, the speed depends on the driver's driving style and vehicle dynamics.

The diversity of influencing factors as well as the observation, that to infer the influencing factors from velocity profiles is difficult, motivate the development of two approaches to analyse velocity profiles. The first approach is *impact-oriented* and the second approach is *cause-oriented*. The impact-oriented analysis will be applied in situations where the decisive influence factor is unknown. In contrast to that, the cause-oriented analysis is applied if the decisive influence factor is known, e. g. given by traffic light position.

This work consists of three main contributions. The first contribution is related to the impact-oriented analysis, the second contribution as well as the third contribution are related to the cause-oriented analysis.

The *impact-oriented* analysis is a generic approach to analyze the influence factors on velocity profiles not in particular, but analyse the impact of combined factors on the velocity profile. Our first contribution in this work is an approach to predict the maximum speed for the next several hundred meters based on typical movements of other vehicles given as historical velocity profiles. The underlying observation is that on most route segments, only a few characteristic velocity profiles exist (imagine for example two characteristic profiles for a road intersecting another road: in one case, an approaching vehicle has to stop in case of cross-traffic, but in another case it may safely cross). If the probabilities for each of these characteristic profiles are known it is possible to predict a short-term *future velocity profile (FVP)*. Based on such a profile, it is possible to calculate a *fuel-reduced velocity profile (RVP)*. Characteristic profiles are calculated by applying a clustering algorithm. The problem in clustering velocity profiles is to measure the similarity of sequences considering that drivers react differently on the same traffic event (a recurrent change in speed at similar position in various velocity profiles), resulting in velocity profiles shifted in location and/or speed. We tackle this problem with a distance measure based on dynamic time warping (DTW). The algorithm is evaluated in a rural and urban environment. Results indicate possible fuel savings of about 8.3% compared to the most probable profile on the road that has been evaluated.

In contrast to the impact-oriented analysis the *cause-oriented* analysis relies on the knowledge of the decisive influence factor at a specific position. In an urban environment velocity profiles are decisive influenced by the state of traffic lights. Given a digital map the positions of intersections and traffic lights are known. Resulting from that, our goal of *cause-oriented* analysis is to inform the driver about the expected traffic light state depending on the time of arrival. Therein, our first idea is to build an autonomous system that is independent from receiving phase schedules sent by roadside units or traffic control centers. Instead, our system learns the phase schedule of the traffic light controller, given as a black box, solely on the basis of velocity profiles shared in a digital cloud. The second idea bases on the fact that traffic light phases are aligned to enable a specific driving pattern for efficient traffic flow. Such correlations between traffic light phase schedules at consecutive intersections can be found in recorded vehicle traces, and – when a vehicle is approaching a traffic light – one can reason from these correlations about the most probable approach at the next traffic light. Both algorithms predict the maximum speed at the next traffic light; the former addresses traffic lights operating

at fixed cycle length over a period of time and the latter addresses coordinated traffic lights.

Our second contribution is an algorithm named *Traffic Light State Estimation* (TLSE) to *backward-estimate* the traffic light phase schedule of traffic lights operating at fixed cycle length over a period of time. For each driving direction (pair of origin and destination arm) at an intersection, TLSE first estimates the direction-specific phase schedule. The traffic light controller at an intersection coordinates red and green times for different directions, where some directions have the right-of-way at the same time (directions are in the same phase) and others are complementary (directions are in different phases). TLSE in a second step leverages the relation between directions to improve the estimation of the direction-specific phase schedules. To evaluate TLSE, we set up simulation scenarios using a traffic simulator and implemented fixed-time as well as signal-adaptation traffic light controller algorithms with constant as well as with time-of-day-dependent traffic flow. We also analyzed the performance of TLSE depending on the number of available velocity profiles. The results are showing that phase schedule prediction on the base of TLSE is correct more than 90 % of the time for fixed-time and 80 % of the time for semi-actuated control algorithms with only 5 % of the vehicles sharing their velocity profile.

Our third contribution is an algorithm named *Traffic Light Coordination Analysis* (TLCorA) to reason from correlations between phase schedules about the most probable approach at the next traffic light. Thereby, when the ego-vehicle is approaching a traffic light, the key idea and major challenge is to determine the current point of time in the phase schedule of a recently passed correlated traffic light. With this information, traces of other vehicles that have approached the upcoming traffic light at the same relative point of time in the phase schedule can be evaluated and the most probable approach can be determined. TLCorA evaluates vehicle traces in the following way: First, while driving towards a signalized intersection, TLCorA filters related traces from other vehicles that have approached the upcoming traffic light in the past. Second, the traces are clustered based on Dynamic Time Warping as distance measure. This results in several classes of approaches with respective occurrence probabilities. A correlation of traffic lights becomes evident if there is a very dominant class. Finally, TLCorA determines a representative velocity profile for each class. To evaluate TLCorA, we set up simulation scenarios and implemented scenarios with different types of traffic light algorithms. We varied the type of control algorithms between pre-timed, semi-actuated, and fully-actuated, with constant as well as with time-of-day-dependent traffic flow.

Danksagung

Diese Doktorarbeit habe ich im Rahmen des Doktorandenprogramms der Volkswagen AG in der Volkswagen Konzernforschung verfasst und bin für die mir gebotenen Möglichkeiten sehr dankbar. Die spannenden Diskussionen mit Kollegen aus den unterschiedlichsten Fachbereichen haben einen wesentlichen Teil zu dieser Arbeit beigetragen.

Außerordentlich dankbar bin ich meinem Doktorvater, Prof. Dr. Martin Mauve, der mit seiner Betreuungszusage und dem mir entgegen gebrachten Vertrauen diese Arbeit überhaupt erst möglich gemacht hat. Er war immer für mich ansprechbar und hat es in jedem unserer Gespräche geschafft, mich zu motivieren („Es gibt keine Probleme, nur Herausforderungen.“). Weiterhin möchte ich Prof. Dr. Björn Scheuermann dafür danken, dass er der Zweitgutachter dieser Arbeit ist.

Ein ganz besonderer Dank gilt Dr. Christian Wewetzer, der meine Arbeit die letzten drei Jahre mit großem Einsatz begleitet hat. Intensive Diskussionen, konstruktives Hinterfragen von Lösungsansätzen und die Unterstützung beim Schreiben der Veröffentlichungen waren außerordentlich wertvoll für diese Arbeit. Außerdem möchte ich Dr. Andreas Sasse und Tilman Klar danken, die immer für Diskussionen zur Verfügung standen und neue Ideen eingebracht haben. Danken möchte ich auch Dr. Murat Caliskan, der mit seinem Einsatz die Anstellung bei VW erst möglich machte und mir in meinem ersten Jahr immer zur Seite gestanden hat. Sehr dankbar bin ich auch für die Unterstützung von Dr. Wolfgang Kiess, der ganz wesentlich zur Schärfung des Themas mit seinen Ideen beigetragen hat. Darüber hinaus danke ich Dr. Bernd Rech, der mich als mein direkter Vorgesetzter immer unterstützt und mir die nötigen Freiräume geschaffen hat.

Abschließend möchte ich meiner Familie danken, die mich in der gesamten Zeit unterstützt und motiviert hat. Insbesondere meine Eltern, mein Bruder und meine Großeltern haben immer wieder großes Interesse an dem Fortschritt meiner Arbeit gezeigt. Ganz besonderer Dank gilt dabei auch meiner Frau, Dr. Léonie F. Kerper, die ein unglaubliches Verständnis für lange Arbeitstage hatte und mich bei der Fertigstellung durch Korrekturlesen unterstützt hat. Weiterhin möchte ich Raphael Lange danken, der diese Arbeit ebenfalls noch einmal Korrektur gelesen hat.

Geheimhaltungszusatz

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

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

Publications about the content of this work require the written consent of Volkswagen AG.

The results, opinions and conclusions expressed in this thesis are not necessarily those of Volkswagen AG.

Inhaltsverzeichnis

Vorwort	i
Zusammenfassung	i
Englische Zusammenfassung	v
Danksagung	ix
Geheimhaltungszusatz	xi
Inhaltsverzeichnis	xiii
Abbildungsverzeichnis	xvii
Tabellenverzeichnis	xix
Abkürzungsverzeichnis	xxi
1 Einleitung	1
1.1 Motivation	1
1.2 Problemdefinition	3
1.3 Struktur der Arbeit	7
2 Fahrprofile	9
2.1 Anwendungsgebiete	10
2.1.1 Berechnung von Verkehrsinformationen	10
2.1.2 Generierung von Karteninformationen	12
2.1.3 Anforderungen an die Genauigkeit und Auflösung	14
2.2 Verwendung in dieser Arbeit	16
2.2.1 Systemarchitektur in dieser Arbeit	16
2.2.2 Definition des Fahrprofils und Anforderungen in dieser Arbeit	18
2.2.3 Vom Fahrprofil zum Geschwindigkeitsverlauf	19
2.3 Datenquellen zur Filterung von Fahrprofilen	20
3 Taktische Fahrtoptimierung	23
3.1 Berechnung eines verbrauchsreduzierten Geschwindigkeitsprofils	24
3.2 Kraftstoffverbrauchssimulation	25
3.3 Kraftstoffeinsparpotenzial	26
3.3.1 Zeitbedarf vs. Potenzial	27
3.3.2 Abhängigkeit zur Vorausschaulänge	28
4 Wirkungsorientierte Analyse von Fahrprofilen	31
4.1 Stand der Technik	32
4.2 Klassifikation und Prognose von Geschwindigkeitsverläufen	35
4.2.1 Dynamic Time Warping als Distanzmaß	37

4.2.2	Berechnung charakteristischer Geschwindigkeitsverläufe	40
4.2.3	Berechnung des repräsentativen Geschwindigkeitsverlaufs	40
4.2.4	Prognose des zukünftigen Geschwindigkeitsverlaufs	42
4.3	Evaluierung des Algorithmus	43
4.3.1	Experimentdurchführung	44
4.3.2	Ergebnisse	45
4.4	Zusammenfassung und Ausblick	56
5	Lichtsignalanlagensteuerung: Grundlagen, Szenarien und Simulation	59
5.1	Allgemeine Einleitung zur Lichtsignalanlagensteuerung	59
5.1.1	Begriffe der Lichtsignalanlagensteuerung	60
5.1.2	Steuerungsverfahren für Lichtsignalanlagen	61
5.2	Auswahl der Simulationsszenarien	66
5.3	Beschreibung der Simulationsumgebung	70
5.4	Verfahren zur Reduzierung des Kraftstoffverbrauchs an Kreuzungen	74
6	TLSE: Ursachenorientierte Analyse zum Lernen der LSA-Schaltzeiten	77
6.1	Schätzen der spezifischen LSA-Parameter einer Fahrtrichtung	78
6.1.1	Extrahieren der Beobachtungen über den LSA-Zustand	79
6.1.2	Schätzung der Umlaufzeit durch Optimierung	80
6.1.3	Schätzung der Länge der Grünzeit	82
6.2	Zusammenführung der spezifischen LSA-Parameter der Fahrtrichtungen	84
6.2.1	Identifikation von verträglichen und nicht verträglichen Fahrtrichtungen	85
6.2.2	Zusammenführung von verträglichen Fahrtrichtungen	85
6.2.3	Zusammenführung von nicht verträglichen Fahrtrichtungen	86
6.3	Evaluierung von TLSE	89
6.4	Zusammenfassung und Ausblick	97
7	TLCorA: Ursachenorientierte Analyse zum Lernen der Korrelation zwischen LSA	99
7.1	Funktionsweise: Identifikation von relevanten Fahrprofilen	101
7.2	Evaluierung von TLCorA	103
7.3	Zusammenfassung und Ausblick	110
8	Zusammenfassung und Ausblick	113
	Literaturverzeichnis	117

Abbildungsverzeichnis

1.1	Einflussfaktoren auf das Fahrprofil	3
1.2	Zehn Geschwindigkeitsverläufe im Bereich einer Kreuzungszufahrt	5
2.1	Kreuzungsmodellierung in modernen digitalen Karten: Einfache Kreuzung (links) und komplexe Kreuzung (rechts) (Quelle Luftbilder: Google Inc.)	13
2.2	Systemarchitektur in dieser Arbeit	17
3.1	Aufbau der Kraftstoffverbrauchssimulation	25
3.2	Zeitbedarf vs. Kraftstoffeinsparpotenzial	27
3.3	Verbrauchsreduzierte Profile bei 1000 m Vorausschau	28
3.4	Verbrauchsreduzierte Profile bei 500 m Vorausschau	28
3.5	Verbrauchsreduzierte Profile bei 300m Vorausschau	29
3.6	Verbrauchsreduzierte Profile bei 100m Vorausschau	29
3.7	Kraftstoffverbrauch bei unterschiedlichen Vorausschaulängen (Kraftstoffverbrauch für 1000 m und 500 m gleich)	30
4.1	Translation des Offsets von zwei Zeitreihen: Auf der linken Seite befinden sich zwei Zeitreihen mit einem Offset von 2,5 und auf der rechten Seite die beiden Zeitreihen nach Translation des Offsets.	34
4.2	Skalierung der Amplitude von zwei Zeitreihen: Auf der linken Seite befinden sich zwei Zeitreihen mit Offset und unterschiedlicher Amplitude, auf der rechten Seite die beiden Zeitreihen nach Translation und Skalierung des Offsets.	34
4.3	Beispielhafter Vergleich zwischen euklidischer Distanz zweier Zeitreihen (links) und DTW (rechts)	35
4.4	Prozess der Berechnung charakteristischer Geschwindigkeitsverläufe mittels wirkungsorientierter Analyse und Anwendung zur Bestimmung des zukünftigen und verbrauchsoptimierten Geschwindigkeitsverlaufs.	36
4.5	Verschiebung realer Geschwindigkeitprofile an einer Kreuzung	38
4.6	Geschwindigkeitsverläufe ohne Verschiebung eines Clusters und daraus resultierendes mittleres Profil m_1 (blaue Linie)	41
4.7	Geschwindigkeitsverläufe mit Verschiebung eines Clusters und daraus resultierendes mittleres Profil m_2 (blaue Linie)	41
4.8	Ausgewählte Messstrecke [Goo].	44

4.9	Darstellung eines Segments mit fester Segmentgröße (links, hier: $s=200$ m) bei Teilung eines Verkehrereignisses und Segmentierung mit variabler Segmentgröße $s \geq 200$ m (rechts)	46
4.10	Oben: Ein Segment mit zwei Verkehrereignissen bei variabler Segmentgröße (hier: $1000 - 1200$ m). Unten: Entsprechende Segmente für die beiden Verkehrereignisse bei variabler Segmentgröße von $200 - 300$ m . . .	48
4.11	Wahrscheinlichkeit für die Anzahl der resultierenden Cluster in Abhängigkeit des Grenzwertes t für den Clusteralgorithmus bei einer variablen Segmentgröße von $x_{min}=200$ m und $x_{max}=300$ m	50
4.12	Geschwindigkeitsverläufe für das Teilstück 2000 m bis 4300 m der Messstrecke und Segmentgrenzen	51
4.13	Cluster für das Teilstück 2000 m bis 4300 m (blaue Linien) der Messstrecke und Segmentgrenzen	52
4.14	FVP in Abhängigkeit der Fahrhistorie unterschiedlicher Länge. Der Parameter a bezeichnet die Anzahl der zurückliegenden Segmente.	53
4.15	Segmentübergreifender Wahrscheinlichkeitsgraph für die Streckendistanz 2700 m bis 4300 m. Hervorgehobene Kanten markieren den wahrscheinlichsten Geschwindigkeitsverlauf.	54
4.16	FVP und optimierte Fahrverläufe (RVPs) für die Messstrecke	55
4.17	Kraftstoffverbrauch in Abhängigkeit der Fahrtzeit der optimierten Geschwindigkeitsverläufe (RVPs)	55
5.1	Algorithmen zur Steuerung von Lichtsignalanlagen nach RiLSA [fSuV10]	63
5.2	Lichtsignalanlagen in Deutschland - Eine Befragung von 21 Städten (Quelle: [Fri09])	65
5.3	Ablauf der Freigabezeitanpassung für Szenario 4 (Quelle: [Oer09]) . . .	68
5.4	Ablauf der Signalprogrammabbildung (Szenario 5) (Quelle: [Oer09])	69
5.5	Das Straßennetzwerk der Simulation bestehend aus fünf benachbarten Knotenpunkten	70
5.6	Die Knotenpunkte in der Simulationsumgebung	73
6.1	LSA-Parameter zweier Fahrtrichtungen: Länge des Zyklus (l_z) in Sekunden, Länge der Grünzeit (l_g) im Zyklus in Sekunden und Offset des Zyklusstarts (dt) zu einem absoluten Referenzzeitpunkt	79
6.2	Zykluslänge und Offset für 100 normalverteilte Zyklusstartzeiten mit $\mu = n \cdot 70 + dt$ und $\sigma = 10$ und $n \in \{1, \dots, 100\}$ (links). Zykluslänge und Offset nach Optimierung der Offsets (rechts). Der reale Offset des Zyklusstarts dt ist 20 s.	82
6.3	Histogramm zur Schätzung der Länge der Grünzeit/Rotzeit	83
6.4	Prozent der korrekten Schätzungen des LSA-Status für Simulationsszenarien mit 100% und 5% Penetrationsrate	90
6.5	Differenz von geschätzten und realen LSA-Parametern: Szenario 1 für eine LSA mit 100% ausgestatteten Fahrzeugen bei einem konstanten Verkehrsfluss von 918 Fzg./Stunde	91

6.6	Differenz von geschätzten und realen LSA-Parametern: Szenario 1 für eine LSA mit 5 % ausgestatteten Fahrzeugen bei einem konstanten Verkehrsfluss von 918 Fzg./Stunde	92
6.7	Differenz von geschätzten und realen LSA-Parametern: Szenario 3 für eine LSA mit 100 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss von 918 Fzg./Stunde	92
6.8	Differenz von geschätzten und realen LSA-Parametern: Szenario 3 für eine LSA mit 5 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss von 918 Fzg./Stunde	93
6.9	Differenz von geschätzten und realen LSA-Parametern zur Umschaltzeit in Szenario 3 für eine LSA und 100 % ausgestattete Fahrzeuge	94
6.10	Differenz von geschätzten und realen LSA-Parametern zur Umschaltzeit in Szenario 3 für eine LSA und 5 % ausgestattete Fahrzeuge	94
6.11	Differenz von geschätzten und realen LSA-Parametern für Szenario 4 mit 100 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss	95
6.12	Differenz von geschätzten und realen LSA-Parametern für Szenario 4 mit 5 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss	95
6.13	Differenz von geschätzten und realen LSA-Parametern für Szenario 5 mit 100 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss	96
7.1	Schritte der Berechnung des zukünftigen Geschwindigkeitsverlaufs bei Zufahrt auf eine durch LSA gesteuerte Kreuzung.	101
7.2	Anzahl der repräsentativen Geschwindigkeitsverläufe (Cluster) berechnet durch TLCorA für die LSA 2 bis 5 in allen Szenarien	105
7.3	Empirische Verteilungsfunktion (EDF) der Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters für Szenario 1 (links) und Szenario 2 (rechts)	107
7.4	Empirische Verteilungsfunktion (EDF) der Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters für Szenario 3 (links) und Szenario 4 (rechts)	107
7.5	Empirische Verteilungsfunktion (EDF) der Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters für das Szenario 5	108
7.6	Einfluss der relativen Zeit zum Phasenbeginn auf die Anzahl der Cluster in Szenario 1	109
7.7	Einfluss der relativen Zeit zum Phasenbeginn auf die Anzahl der Cluster in Szenario 4	110

Tabellenverzeichnis

2.1	Anforderungen an die Frequenz der Datenübertragung und Positionierungsgenauigkeit	19
4.1	Informationen zur gewählten Messstrecke.	44
4.2	Technische Daten des Messfahrzeugs	45
4.3	Eigenschaften des verwendeten u-blox Empfängers	45
4.4	Parameter der Segmentierung	49
5.1	Simulationsszenarien	67
5.2	Konfigurationsparameter der SUMO-Simulation	71

Abkürzungsverzeichnis

C-FCD	Cellular-FCD
CAN	Controller Area Network
DGPS	Differential GPS
DSRC	Dedicated Short Range Communication
DTW	Dynamic Time Warping
EDGE	Enhanced Data rates for GSM Evolution
FCD	Floating Car Data
FVP	Future Velocity Profile
GLOSA	Green Light Optimal Speed Advisory
GPS	Global Positioning System
HMI	Human Machine Interface
IRS	Intelligent Roadside Station
LSA	Lichtsignalanlage
LTE	Long Term Evolution
RSU	Road Side Unit
RVP	Fuel-Reduced Velocity Profile
TLCorA	Traffic Light Correlation Analysis
TLSE	Traffic Light State Estimation
TMC	Traffic Management Code
UMTS	Universal Mobile Telecommunications Systems

Kapitel 1

Einleitung

Weltweit sind Fahrzeughersteller bestrebt den Verbrauch und die Emissionen der Fahrzeuge zu minimieren. Dies geschieht z. B. durch die Entwicklung neuer Antriebskonzepte, Reduzierung der Fahrwiderstände oder Gewichtsreduzierung. Weiterhin fordert die EU-Gesetzgebung, dass ab 2015 alle Neuwagen verpflichtend den CO₂-Wert von maximal 130 Gramm Kohlendioxid je Kilometer nicht überschreiten. Wesentlichen Einfluss auf die Emissionen, den Kraftstoffverbrauch und damit auch die Betriebskosten eines Fahrzeugs hat jedoch nicht nur der Fahrzeugtyp, sondern auch der Fahrer/die Fahrerin¹ durch das Beschleunigungs- und Verzögerungsverhalten. Diverse Studien haben gezeigt, dass *Vorausschauendes Fahren* das Potenzial hat, den Kraftstoffverbrauch um bis zu 20 % zu reduzieren.

Im Rahmen dieser Arbeit werden Algorithmen zur Unterstützung des Fahrers beim vorausschauenden Fahren entwickelt. In Abschnitt 1.1 wird die Arbeit zunächst motiviert. Anschließend werden die in dieser Arbeit adressierten Probleme dargestellt und Lösungsansätze beschrieben (Abschnitt 1.2). In Abschnitt 1.3 folgt eine Zusammenfassung der wissenschaftlichen Beiträge dieser Arbeit.

1.1 Motivation

Ein Fahrer, der das Ziel hat vorausschauend zu fahren, muss die für ihn fahrbare Maximalgeschwindigkeit auf der vorausliegenden Strecke abschätzen, um unnötige Beschleunigungs- und Bremsvorgänge zu vermeiden. Die fahrbare Maximalgeschwindigkeit auf einem Streckenabschnitt unterliegt diversen Beschränkungen, die u. a. aus Streckengeometrie, Verkehrszeichen und der Witterung resultieren. Die dieser Arbeit

¹In dieser Arbeit wird im Folgenden stets die maskuline Form zur Vereinfachung verwendet, wobei natürlich beide Formen möglich sind.

zugrunde liegende Beobachtung ist, dass Fahrer zum einen in komplexen Situationen und auf unbekanntem Strecken aufgrund des Informationsdefizits nicht in der Lage sind, die fahrbare Maximalgeschwindigkeit für die nächsten zwei- bis dreihundert Meter abzuschätzen. Zum anderen ist es für den Fahrer eine große Herausforderung fahrzeugspezifische, verbrauchseffiziente Fahrmanöver aus diesen Informationen abzuleiten. Ein rechtzeitiges Ausrollen bei der Zufahrt auf ein Stoppschild erfordert z. B. das Abschätzen der Distanz zum Schild und des fahrzeugspezifischen Ausrollweges.

Diese Arbeit verfolgt das Ziel, dem Fahrer die oben genannten komplexen Aufgaben, d. h. die Berechnung der fahrbaren Maximalgeschwindigkeit und der daraus resultierenden verbrauchseffizienten Fahrmanöver, mittels eines Assistenzsystems abzunehmen. Der Beitrag dazu in dieser Arbeit ist ein System zur Berechnung der fahrbaren Maximalgeschwindigkeit aus historischen Fahrprofilen. Die Idee dabei ist, die fahrbare Maximalgeschwindigkeit auf dem vorausliegenden Streckenabschnitt durch den Geschwindigkeitsverlauf, den Fahrzeuge typischerweise dort fahren, aus historischen Fahrprofilen abzuschätzen. Dieser typische Geschwindigkeitsverlauf entspricht dann der Geschwindigkeit, die der Fahrer ohne Unterstützung wahrscheinlich fahren würde. Dazu wird die steigende Verfügbarkeit von Kommunikation zwischen Fahrzeugen und Servern genutzt. Fahrzeuge sind dadurch in Zukunft in der Lage, z. B. ihre Fahrprofile (Zeit, Geschwindigkeit, Ort) und andere Beobachtungen (wie Glätte und Regen) an einen Server zu senden.

Die Annahme dabei ist, dass die fahrbare Maximalgeschwindigkeit zu einem bestimmten Zeitpunkt in der Zukunft auf der Strecke aus der Menge der verfügbaren historischen Fahrprofile für diese Strecke berechnet werden kann. Aufgrund der Schwierigkeiten des vorausschauenden Fahrens sind diese Fahrprofile und die daraus resultierende fahrbare Maximalgeschwindigkeit in der Regel nicht verbrauchsoptimal. Daher werden im Anschluss verbrauchseffiziente Fahrmanöver bestimmt und dem Fahrer kommuniziert. Der Schwerpunkt dieser Arbeit liegt auf der Entwicklung der Verfahren zur Analyse der Fahrprofile, um situationsbedingt die fahrbare Maximalgeschwindigkeit zu bestimmen. Basierend auf diesen Verfahren wird außerdem das Potenzial den Verbrauch zu reduzieren untersucht, indem verbrauchseffiziente Fahrmanöver mittels Verbrauchssimulationen bestimmt werden.

1.2 Problemdefinition

Das Ziel dieser Arbeit ist, aus historischen Fahrprofilen die fahrbare Maximalgeschwindigkeit auf dem vorausliegenden Streckenabschnitt zu berechnen. Als Fahrprofil wird in dieser Arbeit eine Folge zeitlich aufeinander folgender Positionsmessungen (Zeit, Ort, Geschwindigkeit)² bezeichnet, welche von einem Fahrzeug aufgezeichnet wurden. Ein solches Fahrprofil ist immer das Resultat einer Fahrt, die durch eine Menge von Faktoren beeinflusst wird (Abbildung 1.1).

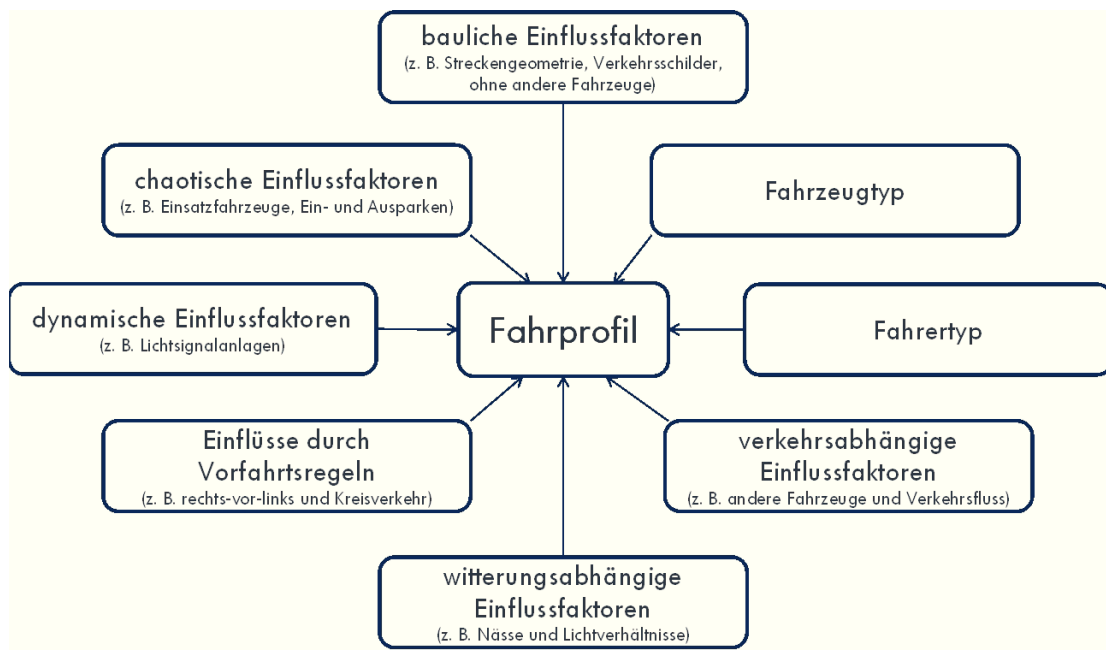


Abbildung 1.1: Einflussfaktoren auf das Fahrprofil

Es stellt sich nun die Frage: Wie kann aus einer gegebenen Menge von Fahrprofilen, die alle unter dem Einfluss verschiedenster Faktoren entstanden sind, die fahrbare Maximalgeschwindigkeit (der typische Geschwindigkeitsverlauf ohne Assistenzsystem) auf dem vorausliegenden Streckenabschnitt berechnet werden?

Zur Beantwortung dieser Frage wird das Problem zunächst vereinfacht. Es wird angenommen, dass lediglich bauliche Einflussfaktoren auf das Fahrprofil wirken und eine Lösung beschrieben, um den typischen Geschwindigkeitsverlauf zu berechnen. Anschließend wird die Anzahl der Einflussfaktoren sukzessiv durch die Einflüsse aus Abbildung 1.1

²Zusätzlich können weitere Informationen, wie z. B. Fahrtrichtung oder Qualität der Positionsmessung, angehängt werden.

(beginnend bei zwölf Uhr im Uhrzeigersinn) erhöht und ebenfalls Lösungsansätze diskutiert.

Für den Fall, dass die Fahrprofile ausschließlich durch bauliche Einflussfaktoren (ohne andere Fahrzeuge, unterschiedliche Fahrzeugtypen und mit immer gleichem Fahrerverhalten) beeinflusst werden, ist die Geschwindigkeit aller Fahrprofile an jedem Ort gleich und das typische Geschwindigkeitsprofil ist einfach zu bestimmen.

Werden Einflüsse durch Fahrzeugtyp und Fahrertyp (z. B. sportlich oder komfortorientiert) mit berücksichtigt, dann entsteht ein schmaler Geschwindigkeitsschlauch über der Strecke, welcher durch die Minimal- und Maximalgeschwindigkeit der Fahrprofile an jeder Position beschrieben ist. Die Geschwindigkeitsunterschiede resultieren aus unterschiedlichem Beschleunigungs- und Verzögerungsverhalten. Eine einfache Lösung zur Bestimmung des typischen Geschwindigkeitsverlaufs sieht in diesem Fall wie folgt aus: Die Fahrprofile werden gefiltert, sodass nur Fahrprofile mit gleichem Fahrzeugtyp und Fahrertyp übrig bleiben. Aufgrund der Ähnlichkeit der verbleibenden Fahrprofile stellen diese im Mittel den typischen Geschwindigkeitsverlauf dar.

Hoher Verkehrsfluss und Witterungseinflüsse haben meistens eine reduzierte Geschwindigkeit zur Folge. Dadurch wird der Unterschied zwischen Minimal- und Maximalgeschwindigkeit aller Fahrprofile signifikant größer. Durch Verwendung entsprechender Filter für Tageszeit und Witterungsbedingungen wird die Ähnlichkeit der verbleibenden Fahrprofile erhöht, sodass das Mittel der relevanten Fahrprofile erneut dem typischen Geschwindigkeitsverlauf entspricht.

Bis zu dieser Stelle ist die Berechnung des typischen Geschwindigkeitsverlaufs auf Basis von Fahrprofilen durch Filterung möglich. Es entsteht durch die vorher genannten Einflussfaktoren und die Filtermethoden jeweils nur ein Geschwindigkeitsschlauch mit geringer Varianz in der Geschwindigkeit. In Vorrangsituationen, in denen das Fahrprofil durch Vorfahrtsregeln oder Lichtsignalanlage (LSA) beeinflusst wird (Fahrzeuge stoppen oder fahren mit annähernd konstanter Geschwindigkeit weiter), ergeben sich zu jeder Tageszeit und Witterungsbedingungen mehrere typische Geschwindigkeitsverläufe. Beispielhaft sind in Abbildung 1.2 zehn Geschwindigkeitsverläufe einer Zufahrt auf eine Kreuzung dargestellt. Fahrzeuge halten an der Kreuzung oder fahren mit leicht verminderter Geschwindigkeit weiter.

Um mit einem Filter auch in einer solchen Situation einen eindeutigen typischen Geschwindigkeitsverlauf bestimmen zu können, müsste dieser entweder alle Fahrprofile mit einem Stopp oder alle Fahrprofile ohne Stopp an der Straßenkreuzung entfernen. Dies

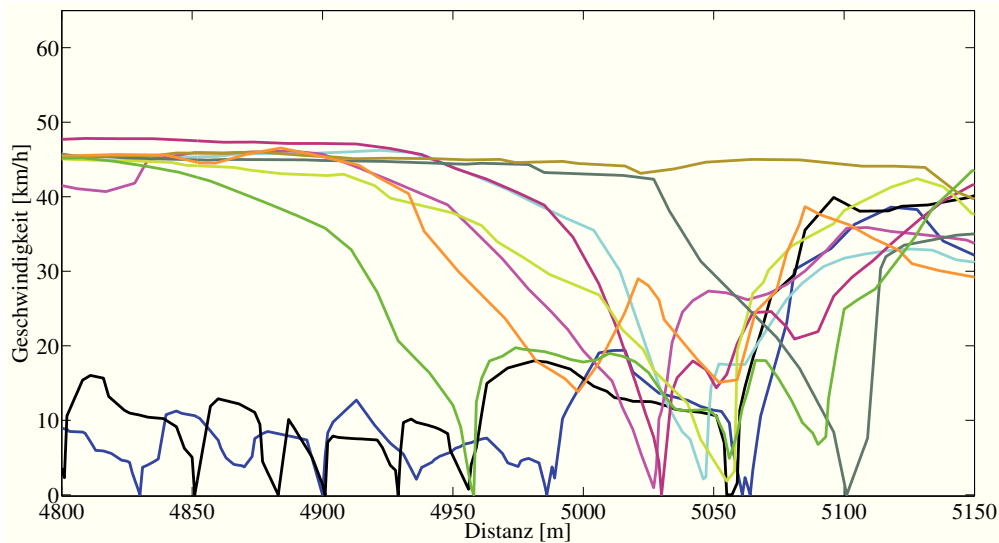


Abbildung 1.2: Zehn Geschwindigkeitsverläufe im Bereich einer Kreuzungszufahrt

ist jedoch nur mit globalem Wissen über die Existenz von anderen Fahrzeugen (im Fall der Vorfahrtsregeln) oder Wissen über die Umschaltzeiten der LSA an der Kreuzung möglich. Ein solcher Filter existiert offensichtlich nicht generell. Das Ziel dieser Arbeit ist es in diesen Situationen die Menge der typischen Geschwindigkeitsverläufe, die sogenannten *charakteristischen* Geschwindigkeitsverläufe, und deren Wahrscheinlichkeit zu berechnen.

Eine Besonderheit von LSA im Straßenverkehr ist ihre hohe zeitliche Variabilität. Der Status kann innerhalb von Sekunden wechseln, wodurch eine verlässliche Berechnung der Wahrscheinlichkeiten ohne Kenntnis der LSA-Umschaltzeiten kaum möglich ist. Es werden daher die folgenden Probleme in dieser Arbeit adressiert:

1. Die Identifikation von charakteristischen Geschwindigkeitsverläufen durch Klassifizierung von Fahrprofilen, die mehreren unbekanntem Einflussgrößen unterliegen (z. B. nicht näher bestimmte Vorfahrtsregelungen oder chaotische Einflussfaktoren) und die Bestimmung der jeweiligen Eintrittswahrscheinlichkeiten wird zuerst adressiert. Das Problem bei der Klassifizierung ist die Wahl eines geeigneten Ähnlichkeitsmaßes für Geschwindigkeitsverläufe. Veränderungen in der Geschwindigkeit aufgrund gleicher Einflussfaktoren an einer ähnlichen Position (ein Verkehrereignis) sind in Geschwindigkeit und/oder Distanz zueinander verschoben. Dies resultiert zum einen aus unterschiedlichem Verhalten von Fahrern und zum anderen auch aus der Verschiebung der Position von Einflussfaktoren.

2. Die Identifikation von charakteristischen Geschwindigkeitsverläufen und ihrer Wahrscheinlichkeit bei Kenntnis des maßgebenden Einflussfaktors am Beispiel von Einflüssen durch LSA wird anschließend adressiert. Das Problem hierbei ist die Prognose des Zustandes der LSA (rot, gelb oder grün) bei Ankunft aus der Menge der Fahrprofile für unterschiedliche Steuerungsalgorithmen. Mit Hilfe dieser Prognose kann anschließend die Wahrscheinlichkeit für die existierenden charakteristischen Geschwindigkeitsverläufe berechnet werden.

In dieser Arbeit werden zwei Analyseverfahren entwickelt, um die Probleme zu adressieren: Die *wirkungsorientierte* und die *ursachenorientierte* Analyse. Dabei werden drei Kernbeiträge beschrieben: Der erste Beitrag ein Algorithmus der wirkungsorientierten Analyse und die weiteren Kernbeiträge sind Algorithmen der ursachenorientierten Analyse.

Der erste Kernbeitrag dieser Arbeit ist ein (wirkungsorientierter) Algorithmus zur Erkennung von charakteristischen Geschwindigkeitsverläufen und deren Wahrscheinlichkeit für jeden Streckenabschnitt. Dazu werden zunächst relevante Fahrprofile auf dem Server durch Filterung nach aktueller Tageszeit, Witterung und Fahrertyp identifiziert. Anschließend werden mittels Klassifizierung die charakteristischen Geschwindigkeitsverläufe aus der Menge der relevanten Fahrprofile erkannt, deren Wahrscheinlichkeiten berechnet und an das Fahrzeug übertragen. Das System im Fahrzeug verwendet diese Informationen daraufhin, um situationsabhängig die fahrbare Maximalgeschwindigkeit und verbrauchseffiziente Fahrmanöver zu berechnen. Das Problem bei der Klassifizierung von Fahrprofilen, ist ein Ähnlichkeitsmaß zu finden, welches die Verschiebung von Fahrprofilen zueinander berücksichtigt; beispielsweise halten Fahrzeuge an einem Stoppschild an unterschiedlichen Positionen bei Rückstau.

Bei der ursachenorientierten Analyse wird die Information über den wesentlichen Einflussfaktor auf das Fahrprofil in die Berechnung einbezogen. Innerorts werden Fahrprofile ganz wesentlich durch den Status von LSA beeinflusst. Die Kenntnis über die Positionen von Kreuzungen und LSA kann zum Beispiel aus einer digitalen Karte oder einer Verkehrszentrale bezogen werden. Die zu lösenden Probleme in dieser Arbeit sind, durch Analyse von Fahrprofilen an durch LSA gesteuerten Kreuzungen, die Schaltzeiten zu schätzen und die Korrelationen zwischen Schaltzeiten aufeinanderfolgender LSA (z. B. bei „grüner Welle“) zu bestimmen. Dazu werden zwei ursachenorientierte Algorithmen (die Kernbeiträge zwei und drei dieser Arbeit) zur Analyse von Fahrprofilen an LSA entwickelt.

Fahrprofile beinhalten ebenfalls zufällige und chaotische Ereignisse, welche sporadisch an unterschiedlichen Orten zu unterschiedlichen Zeiten auftreten. Dadurch sind chaotische Ereignisse in der Menge der Fahrprofile auf einer Strecke als Ausreißer durch die wirkungsorientierte Analyse zu erkennen und werden nicht weiter betrachtet.

1.3 Struktur der Arbeit

Diese Arbeit liefert drei Kernbeiträge zur Berechnung der charakteristischen Geschwindigkeitsverläufe und deren Wahrscheinlichkeiten auf dem vorausliegenden Streckenabschnitt auf Basis von Fahrprofilen.

Der erste Kernbeitrag ist ein Algorithmus zur Identifikation von charakteristischen Geschwindigkeitsverläufen [KWT⁺11], ohne dass die Art der Einflussfaktoren auf die Fahrprofile vorher speziell analysiert werden muss. Dazu wird die zukünftige Strecke in Segmente unterteilt, die Ähnlichkeit aller Fahrprofile innerhalb eines Segmentes bestimmt und mittels Clusterverfahren klassifiziert. Das Problem bei der Klassifizierung von Fahrprofilen, ist ein Ähnlichkeitsmaß zu finden, welches die Verschiebung von Fahrprofilen zueinander berücksichtigt. In dieser Arbeit wird mit Dynamic Time Warping (DTW) ein Ähnlichkeitsmaß gewählt, welches bereits in der Spracherkennung eingesetzt wurde, um gleiche Wörter trotz unterschiedlich schneller Aussprache zu erkennen. Evaluiert wird der Algorithmus mittels realer Fahrprofile. Anschließend wird ein Algorithmus zur Bewertung der Wahrscheinlichkeit von charakteristischen Geschwindigkeitsverläufen über der Strecke vorgestellt. Ergänzend zu diesem Beitrag wird das Potenzial den Kraftstoffverbrauch auf Basis des wahrscheinlichsten Geschwindigkeitsverlaufs zu reduzieren mit Hilfe einer Verbrauchssimulation und verschiedenen verbrauchsreduzierten Geschwindigkeitsverläufen untersucht.

Der zweite Kernbeitrag dieser Arbeit ist Traffic Light State Estimation (TLSE), ein System zum Lernen der LSA-Umschaltzeiten auf Basis von Fahrprofilen [KWSM12]. Dazu werden „Beobachtungen“ aus Fahrprofilen über den LSA-Status über der Zeit extrahiert, die Umschaltzeiten in der Vergangenheit analysiert, um daraus auf die Parameter (Umlaufzeit und Länge der Grün- bzw. Rotphasen) zu schließen, welche die Schaltzeiten der LSA beschreiben. Die Parameter werden in dieser Arbeit als LSA-Parameter bezeichnet. Dies geschieht in zwei Schritten: Zuerst werden die LSA-Parameter einzelner Fahrrichtungen geschätzt und anschließend wird die Stabilität der Schätzungen erhöht, indem die Schätzungen der einzelnen Fahrrichtungen kombiniert werden. Mit Hilfe der Parameter lässt sich der Status der LSA zu jedem Zeitpunkt in der Zukunft (z. B. zum

Ankunftszeitpunkt des Fahrzeugs) bestimmen. Evaluiert wird der Algorithmus unter Verwendung einer Verkehrssimulation, in welcher unterschiedliche Steuerungsverfahren von LSA implementiert wurden.

Der dritte Kernbeitrag dieser Arbeit ist (Traffic Light Correlation Analysis (TLCorA) [KWM12]) Algorithmus zur Erkennung von Korrelationen zwischen LSA, um aus dem Geschwindigkeitsverlauf an der zurückliegenden LSA auf die fahrbare Maximalgeschwindigkeit an der vorausliegenden LSA zu schließen. Hierbei ist die Idee, zunächst den relativen Zeitpunkt zum Phasenplan einer in der Vergangenheit passierten LSA zu berechnen. Unter der Annahme, dass dieser Phasenplan mit dem Phasenplan der vorausliegenden LSA korreliert ist, können aus der Menge aller Fahrprofile mit ähnlichem relativen Zeitpunkt zum Phasenplan charakteristische Geschwindigkeitsverläufe und deren Wahrscheinlichkeit berechnet werden. Zur Klassifikation von Geschwindigkeitsverläufen wird dabei erneut DTW genutzt. In Simulationsszenarien wird gezeigt, dass die Berechnung des relativen Zeitpunkts und die darauf basierenden charakteristischen Geschwindigkeitsverläufe geeignet sind, mit hoher Wahrscheinlichkeit den zukünftigen Geschwindigkeitsverlauf vorherzusagen.

Die Arbeit ist folgenderweise strukturiert: In Kapitel 2 wird der Stand der Technik beschrieben und die bisherigen Anwendungsgebiete für Fahrprofile. Außerdem werden Kommunikationswege betrachtet, die Auflösung und Genauigkeit diskutiert sowie die Verwendung von Fahrprofilen und der daraus abgeleiteten Systemarchitektur in dieser Arbeit beschrieben. Anschließend werden in Kapitel 3 die Grundlagen der Algorithmen zur Berechnung von verbrauchsreduzierten Geschwindigkeitsprofilen dargestellt, welche in dieser Arbeit verwendet werden. Kapitel 4 beschreibt den ersten Beitrag dieser Arbeit; die Identifikation von charakteristischen Geschwindigkeitsverläufen mittels DTW. In Kapitel 5 werden daraufhin die Grundlagen der LSA-Steuerung, die daraus abgeleiteten Simulationsszenarien und die Simulationsumgebung beschrieben. Der Algorithmus zum Erlernen der LSA-Parameter wird in Kapitel 6 beschrieben und mittels der Simulation an den vorher beschriebenen Szenarien evaluiert. Im darauf folgenden Kapitel 7 wird der Algorithmus zur Berechnung der Korrelation zwischen aufeinander folgenden LSA beschrieben und ebenfalls in der Simulation evaluiert. In Kapitel 8 werden die Ergebnisse dieser Arbeit zusammengefasst und zukünftige Arbeiten diskutiert.

Kapitel 2

Fahrprofile

Mit der Einführung telematischer Systeme entstand zum ersten Mal die Möglichkeit, Informationen von einem *Backend* an Fahrzeuge zu senden und von diesen zu empfangen. Für das periodische Senden von Fahrzeugposition und -geschwindigkeit wurde der Begriff Floating Car Data (FCD) etabliert. Auf Basis der Informationen der Fahrzeuge entstanden zwei für diese Arbeit relevante Anwendungsgebiete: Die Berechnung von Verkehrsinformationen und die Generierung von Straßenkarten.

Aktuelle Navigationsgeräte verwenden z. B. solche Verkehrsinformationen um die Restreisezeit zu berechnen [Sch09, STBW02, HLO99]. Aber auch moderne Fahrerassistenzsysteme basieren auf Verkehrsinformationen, um beispielsweise den Fahrer vor Gefahrenstellen zu warnen [KDH⁺05, KRPK11]. Diese Funktionen erfordern unterschiedliche Genauigkeiten der Verkehrsinformationen, die wiederum eine bestimmte Güte der Fahrzeugdaten implizieren. Die Güte der Fahrzeugdaten kann in diesem Fall als Genauigkeit der zugrunde liegenden Positionsbestimmung im Fahrzeug, der Aktualität und der Frequenz der Daten verstanden werden. Auch Funktionen, die auf Straßenkarten basieren, können ganz unterschiedliche Anforderungen an deren Genauigkeit und Detailgrad haben. Beispielsweise benötigt eine Funktion mit dem Ziel, eine Route von A nach B zu berechnen, ein Straßennetz aus Knoten und Kanten, wohingegen eine Assistenzfunktion zur automatisierten Längsführung u. a. Informationen über die genaue Streckengeometrie benötigt [DJTZ11]. Diverse Arbeiten beschäftigen sich mit der Generierung von Kartendaten aus FCD, um die Anforderungen neuer Assistenzsysteme zu erfüllen [BEJS05, CK10, SWR⁺04].

In diesem Kapitel wird zunächst einen Überblick über die unterschiedlichen Anwendungsgebiete (Abschnitt 2.1) gegeben. Dabei liegt der Schwerpunkt auf der Generierung von Streckendetailkarten und Kreuzungsgeometrien, da diese Grundlage für die in dieser Arbeit entwickelten Algorithmen sind. In Abschnitt 2.2 werden die Begriffe Fahrprofil

und Geschwindigkeitsverlauf für diese Arbeit definiert, die Anforderungen an die Güte der Fahrzeugdaten in dieser Arbeit formuliert und die grundlegende Systemarchitektur beschrieben.

In dieser Arbeit wird eine Filterung von Fahrprofilen vor der eigentlichen Verarbeitung durchgeführt. Dies kann z. B. eine zeitliche Filterung, aber auch eine Filterung nach Wetter- oder Verkehrslage sein. In Abschnitt 2.3 werden Datenquellen für die Filterung der Fahrprofile vorgestellt.

2.1 Anwendungsgebiete

Aktuelle und historische Verkehrsinformationen werden heutzutage schon von Navigationsgeräteherstellern zur Berechnung von zeitlich schnellster, räumlich kürzester oder auch verbrauchseffizientester Route [Bar10] genutzt. Die Wahl oder auch Anpassung der Fahrtroute während der Fahrt wird als *strategische* Maßnahme zur Optimierung der Fahrtroute bezeichnet und ist komplementär zu *taktischen* Maßnahmen, wie sie beim Vorausschauenden Fahren eingesetzt werden. In Abschnitt 2.1.1 werden Arbeiten zur Bereitstellung von Informationen für strategische Maßnahmen vorgestellt und die jeweilige Verwendbarkeit für taktische Maßnahmen in dieser Arbeit diskutiert.

Für die ursachenorientierte Analyse in dieser Arbeit wird Wissen über statische Einflussfaktoren im Straßenverkehr vorausgesetzt. In dieser Arbeit ist das im Speziellen das Wissen über die Position von LSA und die Streckengeometrien im Kreuzungsbereich. Da diese Informationen nicht Teil kommerzieller Navigationskarten sind, werden in Abschnitt 2.1.2 Verfahren zur Generierung der Informationen aus FCD beschrieben.

Anforderungen an die Genauigkeit und Auflösung von Fahrprofilen für die unterschiedlichen Anwendungsgebiete werden in Abschnitt 2.1.3 beschrieben und mit den Anforderungen an die Genauigkeit der Positionsbestimmung in dieser Arbeit verglichen.

2.1.1 Berechnung von Verkehrsinformationen

In den letzten Jahren sind FCD eine verlässliche und genaue Quelle für Verkehrsinformationen geworden. Anfänglich wurde FCD als ergänzende Quelle für Verkehrsinformationen für bereits existierende Infrastruktursysteme, wie z. B. Induktionsschleifen auf Autobahnen oder an Kreuzungen, gesehen [WLL96]. Dabei ging es im Wesentlichen um die

Bestimmung der Verkehrsdichte, des Verkehrsflusses und Verkehrsstörungen durch Kombination der beiden Informationsquellen. Mit dem Ziel die Anzahl der stationären Sensoren zur Verkehrsüberwachung reduzieren und trotzdem verlässliche Reisezeitschätzungen durchführen zu können, wurden in der Folgezeit diverse Projekte [Kör08, STBW02] realisiert. In diesen Arbeiten wurden Taxi-Flotten mit einer Funkeinheit ausgestattet und dadurch tageszeitabhängig die Verkehrslage in den Städten bestimmt. Die Verkehrslage wird als durchschnittliche gefahrene Geschwindigkeit pro Streckenabschnitt auf Basis von Geschwindigkeits- und Positionsinformationen der Fahrzeuge bestimmt, wobei die Fahrzeuge alle 5 bis 60 Sekunden die Informationen an eine Verkehrszentrale schicken, in der anschließend die Gesamtverkehrslage berechnet wird.

Durch den Aufbau mehrerer FCD (Taxi-)Flotten und Kommerzialisierung von portablen *live*-Navigationsgeräten mit der Möglichkeit Daten an eine Verkehrszentrale zu schicken (z. B. durch [Sch09]), sind aufgrund der Menge an Daten diverse Möglichkeiten zur Nutzung entstanden. Zum einen werden aus historischen FCD tageszeit- und wochentagsabhängige Durchschnittsgeschwindigkeiten bestimmt und in modernen Navigationsgeräten integriert, um die Routen- und Reisezeitberechnung zu unterstützen. Zum anderen werden die historischen Daten in den Online-Navigationsgeräten mit *live*-Daten angereichert, um auch auf außerplanmäßige Verkehrsflussstörungen reagieren zu können. Weiterhin werden historische Daten zur Erstellung von genauen Quelle-Ziel-Matrizen für Verkehrssimulationen verwendet [Tur00].

Ergänzend zu FCD werden seit einigen Jahren Mobiltelefone als Datenquelle verwendet [STK05]. Mobilfunkbetreiber errechnen dazu Bewegungsmuster im Mobilfunknetz und bieten diese Daten unter dem Namen Cellular-FCD (C-FCD) an. Auf Basis dieser Daten wurde unter anderem in [BG07, HPaP08] untersucht, inwieweit diese Daten zur Generierung von Verkehrsinformationen genutzt werden können. Mit der Verbreitung von Smartphones mit integriertem Global Positioning System (GPS)-Empfänger existiert noch eine weitere Quelle für FCD. Auch diese Daten werden heutzutage bereits in kommerziellen Produkten verwendet [Sch09].

Die genannten Studien haben gezeigt, dass Verkehrsinformationen auf Basis von FCD generiert werden können. Mit der weiteren Verbreitung von Sendern wird die Qualität der Informationen auch weiterhin zunehmen und ist damit gut geeignet, um strategische Maßnahmen zur Verbesserung des globalen und individuellen Verkehrsflusses durchzuführen. Taktische Maßnahmen, wie z. B. das Vorausschauende Fahren zur Reduzierung des Kraftstoffverbrauchs, sind mit den aktuellen Verfahren allerdings nicht realisiert worden. Dies liegt zum einen daran, dass der Fokus der Forschung bisher auf der Ver-

besserung der Navigationsfunktion liegt, zum anderen aber auch an der Genauigkeit der Positionsinformationen von FCD. Einfache GPS-Empfänger, wie z. B. in Navigationsgeräten oder Smartphones, erreichen eine Genauigkeit von unter zehn Metern in 95 % der Fälle [HB01]. In Großstädten kann die Positionsbestimmung jedoch aufgrund von Abschattung der Funkwellen auch schlechter sein. Eine Bestimmung, auf welchem Streckenabschnitt das Fahrzeug gerade fährt, ist somit möglich, eine ausreichende Positionsbestimmung für die Algorithmen in dieser Arbeit jedoch nicht. Die Anforderungen an die Positionsbestimmung für diese Arbeit werden in Abschnitt 2.1.3 beschrieben. Informationen aus C-FCD sind hingegen gar nicht nutzbar, da diese nur eine ungefähre Positionierung zulassen und ungenauer als Geräte mit GPS-Empfänger [HWH⁺10] sind.

2.1.2 Generierung von Karteninformationen

Für die ursachenorientierte Analyse in dieser Arbeit wird Wissen über statische Einflussfaktoren im Straßenverkehr vorausgesetzt. Im Allgemeinen sind dies Streckengeometrie und Attribute, wie z. B. Verkehrsschilder und Haltelinien, im Speziellen aber auch Wissen über die möglichen Fahrtrichtungen (als Quelle-Ziel-Matrix) und die Existenz von LSA an Kreuzungen. Das Fehlen und die Aktualität der Informationen in digitalen Karten ist der Grund für die Entwicklung von Algorithmen zur Bestimmung der Informationen aus FCD. Im Folgenden wird ein Überblick über Algorithmen zur Bestimmung von Streckengeometrie und Attributen (Abschnitt 2.1.2.1) und die Erzeugung von Kreuzungsdetaillkarten (Abschnitt 2.1.2.2) gegeben.

2.1.2.1 Streckengeometrien und Attribute

Digitale Karten beinhalten heutzutage Informationen zur Berechnung von Routen und zur Realisierung von Navigationsfunktionen, welche eine Anzeige von Fahrhinweisen enthält. Eine auf wenige Zentimeter genaue Karte, die eine genaue Geometriebeschreibung der einzelnen Fahrspuren enthält, ist dazu nicht erforderlich und daher auch nicht Teil von heutigen digitalen Karten. Moderne Fahrerassistenzsysteme und -informationssysteme benötigen jedoch detaillierte und aktuelle digitale Karten. Aus diesem Grund gibt es diverse Arbeiten mit dem Ziel, eine fahrstreifengenaue digitale Karte zu erstellen [SWR⁺04, ES03, CK09, CK10]. Die Grundlage dieser Arbeiten ist das Sammeln und Speichern von Positionsmessungen vieler Fahrzeuge im ersten Schritt. Anschließend werden die Messungen zur Reduzierung des Messrauschens gefiltert und

eine Glättung der Bewegungsprofile vorgenommen. Im nächsten Schritt werden in der Regel parallel laufende Bewegungsprofile zusammengefasst und eine mittlere Streckenlinie berechnet. Mit dieser ist es bereits möglich, Kreuzungen anhand der Schnittpunkte der Streckenlinien und auch die jeweilige Anzahl der Fahrstreifen anhand der Distanz einzelner Bewegungsprofile zur mittleren Streckenlinie zu berechnen. Die Genauigkeit der aufgenommenen Positionsmessungen hat dabei einen wesentlichen Einfluss auf die Genauigkeit der resultierenden digitalen Karte.

Weiterhin gibt es Arbeiten mit dem Ziel, die Streckengeometrie in bestimmten Situationen (wie z. B. in Baustellen [PKS09, KPKT10]) zu erkennen. Da der Fokus der vorliegenden Arbeit auf Kreuzungen liegt, werden im folgenden Abschnitt Arbeiten zur Erkennung von detaillierten Kreuzungsgeometrien beschrieben.

2.1.2.2 Kreuzungsdetailkarten

Digitale Karten beinhalten im Kreuzungsbereich Informationen, die für eine Navigation erforderlich sind. Im Wesentlichen handelt es sich dabei um die Abbiegemöglichkeiten der Fahrzeuge. Die Genauigkeit und der Detailgrad der Karten entsprechen dabei nicht den Anforderungen moderner Assistenz- und Informationssysteme, da die benötigten Informationen bisher nicht im Fokus der Erstellung von digitalen Karten standen. Abbildung 2.1 zeigt die typische Streckengeometrie zweier Kreuzungen in modernen digitalen Karten.




Abbildung 2.1: Kreuzungsmodellierung in modernen digitalen Karten: Einfache Kreuzung (links) und komplexe Kreuzung (rechts) (Quelle Luftbilder: Google Inc.)

Insbesondere für die ursachenorientierte Analyse in dieser Arbeit sind Informationen aus existierenden digitalen Karten nicht ausreichend, da z. B. die Informationen zur Position von Haltelinien gänzlich fehlen. Es existieren jedoch diverse Arbeiten zum Thema Erstellung von Kreuzungsdetaillkarten [FK10, CK09] und zur Detektion von Haltelinien aus FCD, aber auch zur Erkennung von Haltelinien mittels im Fahrzeug verbauten Kamerasystemen [MNDN11]. Ein weiterer Ansatz ist die Erkennung von Straßenmarkierungen aus Luftbildern [HB03]. Mit den jeweils zur Verfügung stehenden Möglichkeiten können die Algorithmen dieser Arbeit mit den nötigen Informationen initialisiert werden.

2.1.3 Anforderungen an die Genauigkeit und Auflösung

Die Berechnung von Verkehrsinformationen und die Bestimmung von Streckengeometrien oder Kreuzungsdetaillkarten stellen ganz unterschiedliche Anforderungen an die Genauigkeit und die Auflösung (Sendefrequenz) von FCD. Aus diesem Grund wird zunächst ein Überblick über die Methoden zur Positionsbestimmung in Fahrzeugen gegeben. Die Sendefrequenz hat dabei einen wesentlichen Einfluss auf das benötigte Datenvolumen und damit auch auf die Kosten zur Übertragung der Daten über ein Mobilfunknetz. Abschließend werden die Anforderungen für die Berechnung von Verkehrsinformationen und Kreuzungsdetaillkarten für FCD beschrieben.

Zur fahrzeugseitigen Positionsbestimmung werden unterschiedliche Sensor- und Informationsquellen eingesetzt. In [SH09] wird ein Überblick über die Quellen und deren Fusion zur Positionsbestimmung gegeben. Informationsquellen sind hier unter anderem GPS-Empfänger, Bewegungssensoren des Fahrzeugs, Straßenkarten und Fahrzeugmodelle.

Einfache GPS-Empfänger, wie z. B. in [ubAb] beschrieben, erreichen dabei bereits eine Genauigkeit von 2,5 m in über 50 % der Zeit. Durch Differential GPS (DGPS) kann die Genauigkeit noch erhöht werden. Dabei werden von fest installierten Stationen Korrektursignale an den GPS-Empfänger gesendet. Mit DGPS kann ein Fehler von <1 m erreicht werden.

Nicht nur die Genauigkeit der Positionsbestimmung im Fahrzeug beeinflusst die Algorithmen basierend auf diesen Daten, sondern auch die Frequenz, in der die Positionen bestimmt und übertragen werden. Einfache GPS-Empfänger haben eine Frequenz von 1-5 Hertz (Hz). Bei einer Fusion mit den Bewegungssensoren des Fahrzeugs ist eine viel höhere Frequenz möglich (>10 Hz).

Fahrprofile werden nach der Positionsbestimmung im Fahrzeug über eine drahtlose Kommunikationsschnittstelle, wie z. B. Enhanced Data rates for GSM Evolution (EDGE), Universal Mobile Telecommunications Systems (UMTS) oder Long Term Evolution (LTE), an einen Server übertragen. Aufgrund der begrenzten Bandbreite solcher Systeme und den auch daraus entstehenden Kosten, ist es nicht möglich, Fahrprofile mit maximaler Anzahl der Positionen pro Sekunde zu versenden. Aus diesem Grund werden z. B. mit [KKKM11, KBMS11, KM11] Arbeiten zur Kompression von Fahrprofilen vorgestellt, mit welchen die benötigte Bandbreite und die Kosten reduziert werden können.

Die Anforderungen an die Positionsbestimmung für die unterschiedlichen Anwendungen, wie beispielsweise zur Berechnung der Verkehrssituation oder von Kreuzungsdetaillkarten, unterscheiden sich deutlich. Aus diesem Grund muss für jede Anwendung eine Anforderungsanalyse durchgeführt werden, aus der hervorgeht, welche Genauigkeit der Positionsbestimmung die gesammelten Fahrzeugpositionen (und auch andere Fahrzeugdaten) liefern müssen.

Das Ziel bei der Berechnung der Verkehrssituation ist in der Regel die Bestimmung des Verkehrsflusses oder der durchschnittlichen Geschwindigkeit auf einem Segment einer digitalen Karte. Um diese Durchschnittsgeschwindigkeit berechnen zu können, müssen die einzelnen Positionsinformationen der Fahrprofile auf der digitalen Karte abgebildet werden. Die Anforderung an die Positionsgenauigkeit ist also, dass die Fahrzeugposition stets einem Segment der Karte zugeordnet werden kann. Eine Genauigkeit mit einem Fehler von 5-10 m (wie von einfachen GPS-Empfängern bereitgestellt) ist daher in der Regel ausreichend. Die entsprechenden Messungen können dabei auch mit geringeren Frequenzen als einmal pro Sekunde aufgezeichnet und übertragen werden.

Bei der Berechnung von Kreuzungsdetaillkarten sind die Anforderungen an die Positionsgenauigkeit deutlich höher. Kreuzungsdetaillkarten sind spurgenaue Karten, woraus direkt eine spurgenaue Positionsgenauigkeit folgt. In der Regel sollte der Fehler der Positionsbestimmung nicht größer sein als die halbe Spurbreite.¹ Entsprechend wird auch in [SWR⁺04] eine DGPS Positionsbestimmung gefordert. Um insbesondere Kurvenfahrten möglichst detailliert beschreiben zu können, ist eine Aufzeichnung der Position mehrmals in der Sekunde erforderlich.

Die Anforderungen an die Positionsgenauigkeit für die Algorithmen dieser Arbeit werden im folgenden Abschnitt beschrieben.

¹Würde das Fahrzeug in der Mitte der Fahrspur fahren, wäre eine Spurzuweisung möglich.

2.2 Verwendung in dieser Arbeit

In dieser Arbeit werden basierend auf Fahrprofilen Algorithmen zur Unterstützung des Fahrers beim Vorausschauenden Fahren entwickelt. In diesem Abschnitt wird zunächst die Systemarchitektur beschrieben (siehe Abschnitt 2.2.1). Anschließend wird der Begriff des Fahrprofils für diese Arbeit definiert und die Anforderungen an Genauigkeit und Auflösungen spezifiziert (siehe Abschnitt 2.2.2). Für die wirkungsorientierte Analyse in dieser Arbeit wird eine Transformation eines Fahrprofils in einen Geschwindigkeitsverlauf vorausgesetzt. Dabei wird aus einem Fahrprofil ein zweidimensionaler Verlauf (Geschwindigkeit über der Strecke) mit Hilfe einer digitalen Karte erzeugt. Dieser Vorgang wird in Abschnitt 2.2.3 dargestellt.

2.2.1 Systemarchitektur in dieser Arbeit

In diesem Abschnitt wird ein Überblick über die Systemarchitektur in dieser Arbeit gegeben. Abbildung 2.2 zeigt zum einen die Fahrzeugflotte und die Komponenten in den einzelnen Fahrzeugen, zum anderen aber auch die Serverkomponenten sowie die Kommunikation zwischen den Fahrzeugen und dem Server.

Im Fahrzeug sind die Komponenten Controller Area Network (CAN)-Bus, Ortung und Kommunikation, die Basis für den FCD Sender und die Applikationen im Fahrzeug. Die Anzeigekomponente ist hier lediglich zur Vollständigkeit dargestellt. Der FCD Sender zeichnet periodisch (mit einer vorgegeben Frequenz) Positionsinformationen und CAN-Daten auf, um diese anschließend über ein Mobilfunknetz an den Server zu versenden. Das Senden kann sofort nach Aufzeichnung der Daten oder auch erst später nach dem Zusammenfassen mehrerer Messungen begonnen werden. Auf der anderen Seite empfangen die Applikationen im Fahrzeug Informationen des Servers, um daraus entsprechende Handlungsanweisungen für den Fahrer über das Human Machine Interface (HMI) zu generieren oder auch eine automatische Längsregelung über den CAN-Bus zu realisieren. In dieser Arbeit liegt der Fokus auf der Bereitstellung der Informationen, jedoch nicht auf der Entwicklung eines HMI oder einer effizienten Längsregelung. Die Anzeigekomponente ist hier nur zur Vollständigkeit dargestellt.

Auf dem Server werden die Daten von den einzelnen Fahrzeugen empfangen, verarbeitet und dann die daraus berechneten Informationen entsprechend der Applikationen wieder an die Fahrzeuge verteilt. Die Komponente FCD Empfänger speichert die Fahrzeugdaten

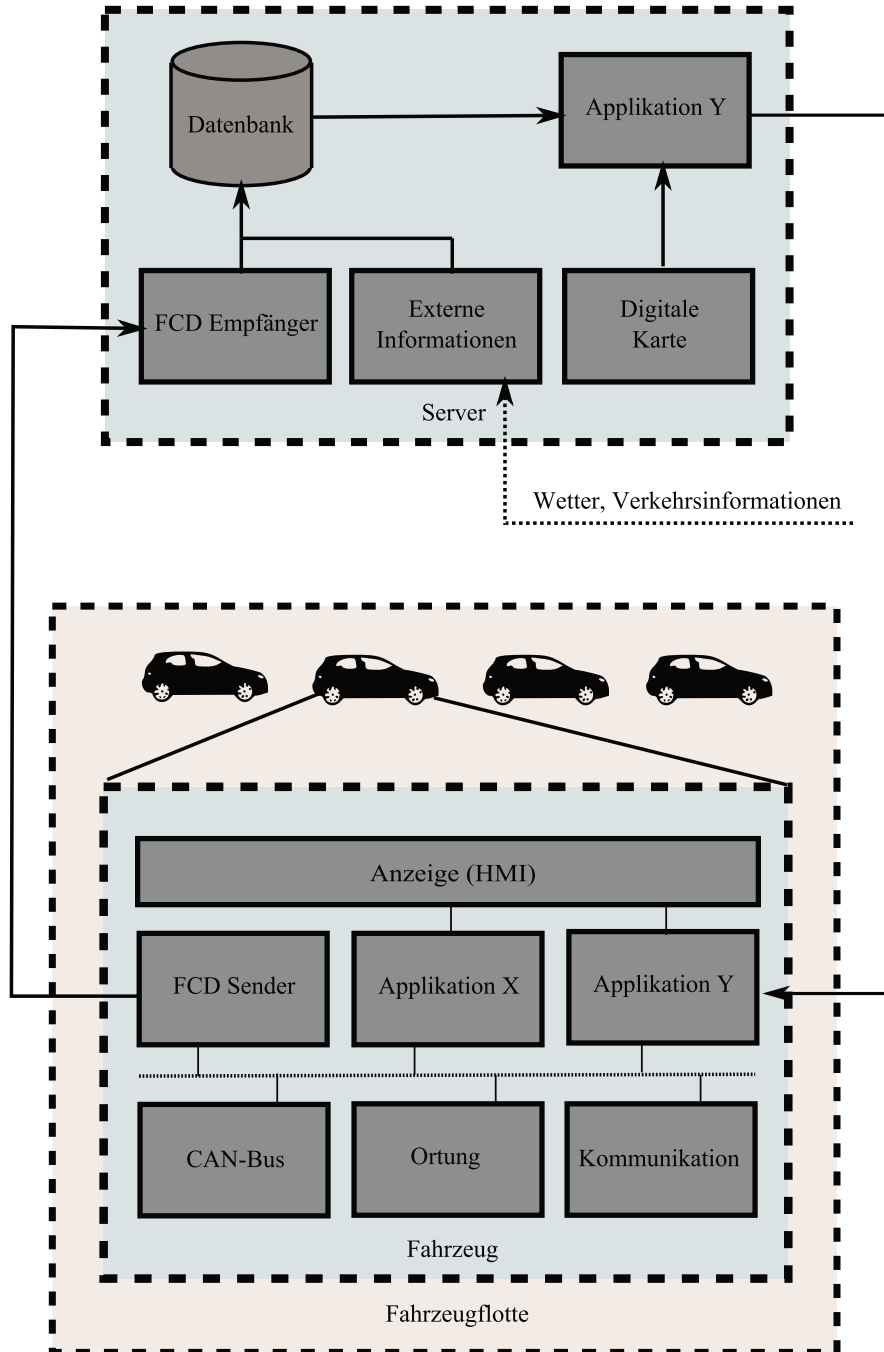


Abbildung 2.2: Systemarchitektur in dieser Arbeit

zunächst in einer Datenbank. Zusätzlich werden Informationen über die aktuelle Verkehrslage und aktuelles Wetter von externen Datenlieferanten empfangen und ebenfalls in der Datenbank gespeichert. Beispiele für diese Informationen sind in Abschnitt 2.3 beschrieben. Applikationen, wie z. B. die wirkungsorientierte oder ursachenorientierte Analyse, arbeiten daraufhin auf Basis der in der Datenbank enthaltenen Informationen sowie einer digitalen Karte. Mittels der digitalen Karte wird in der wirkungsorientierten Analyse ein *Map-Matching*, das Abbilden von empfangenen Fahrzeugdaten auf die digitale Karte, durchgeführt. Das Vorgehen wird in Abschnitt 2.2.3 beschrieben. Die ursachenorientierte Analyse verwendet die Positionen von Knotenpunkten im Straßennetzwerk und die zugehörigen Haltelinien aus der digitalen Karte.

Das Ergebnis der Berechnung der Applikationen wird im letzten Schritt an die Fahrzeuge zurückgesendet. Dabei enthalten Fahrzeuge in Abhängigkeit ihrer geografischen Position nur die aktuell relevanten Informationen.

2.2.2 Definition des Fahrprofils und Anforderungen in dieser Arbeit

Ein Fahrprofil beschreibt eine Menge von geografisch und zeitlich referenzierten Geschwindigkeitsmessungen über einem Zeitabschnitt (z. B. die Fahrt von einem Ort A zu einem Ort B). Dabei können neben der Geschwindigkeit auch weitere Messwerte des Fahrzeugs aufgenommen und mit der gleichen Referenz versehen werden. In dieser Arbeit ist das *Fahrprofil* eine Folge von Zeit-, Positions-, und Geschwindigkeitsmessungen. Dabei liegt das GPS und der CAN-Bus des Fahrzeugs zugrunde, welche die benötigten Messgrößen bereitstellen. Das GPS liefert eine geografische und zeitliche Referenz, welche dann mit Daten des CAN-Bus angereichert werden kann. Durch Verwendung von GPS Zeitstempeln ergibt sich zudem eine zeitliche Synchronität aller Fahrzeugmessungen. Falls kein Zugriff auf die Fahrzeugdaten des CAN-Bus möglich ist, dann kann die Geschwindigkeitsmessung auch mittels des GPS durchgeführt werden. Aufgrund der Genauigkeit der fahrzeugeigenen Messungen sind diese jedoch zu bevorzugen. Insbesondere bei Stillstand des Fahrzeugs oder beim Fahren im Rückwärtsgang liefert der CAN-Bus bessere Informationen als die Messungen des GPS.

Im Fahrzeug werden die Daten gesammelt und dann über eine drahtlose Kommunikationsschnittstelle übertragen. Dabei kann entweder der Weg über die Mobilfunknetze (z. B. EDGE, UMTS, LTE) oder auch über sogenannte Intelligent Roadside Station (IRS) gewählt werden. Bei dem zweiten Weg werden die Daten zunächst mittels ETSI ITS G5 (IEEE 802.11p) Standard an eine IRS und anschließend von dort aus über

einen beliebigen Kommunikationskanal zum Server übertragen. In dieser Arbeit sind beide Kommunikationswege möglich. Die Übertragung ist dabei zeitlich unkritisch und kann im Bereich von mehreren Sekunden liegen, da die Daten nicht sofort bei Empfang verarbeitet werden müssen.

Die Frequenz der Datenaufzeichnung und -übertragung und die Genauigkeit des verwendeten Positionierungssystems beeinflussen die Güte der Algorithmen dieser Arbeit. Die Anforderungen sind in Tabelle 2.1 dargestellt.

	Datenaufzeichnung	Positionierung
Wirkungsorientierte Analyse	1 Hz	Einfacher GPS-Empfänger
Ursachenorientierte Analyse	1 Hz	Koppelortung (GPS + Fahrzeugsensorik)

Tabelle 2.1: Anforderungen an die Frequenz der Datenübertragung und Positionierungsgenauigkeit

Für die wirkungsorientierte Analyse wird lediglich ein einfacher GPS-Empfänger vorausgesetzt, der zur Verbesserung der Geschwindigkeitserkennung (insbesondere bei stehendem oder sehr langsam fahrendem Fahrzeug) mit den fahrzeugeigenen Sensoren gekoppelt werden kann. Die Datenaufzeichnung ist mit einem Datensatz pro Sekunde häufiger als die von existierenden FCD-Flotten (wie z. B. Taxi-FCD), jedoch entspricht sie der Frequenz von modernen Online-Navigationssystemen.

2.2.3 Vom Fahrprofil zum Geschwindigkeitsverlauf

In dieser Arbeit wird neben dem Begriff des Fahrprofils auch der Begriff des *Geschwindigkeitsverlaufs* verwendet. Ein Geschwindigkeitsverlauf ist definiert durch eine Folge von Tupeln (d_i, v_i) mit $i \in \mathbb{N}$ bestehend aus Distanz und Geschwindigkeit. Dabei gibt die Distanz d_i den relativen Bezugspunkt auf einer vorher definierten Route und v_i die Geschwindigkeit an dieser Position an. Aus einem Fahrprofil kann für eine gegebene Route der Geschwindigkeitsverlauf berechnet werden, wodurch das Vergleichen von unterschiedlichen Fahrprofilen erst möglich wird. Dabei werden die Fahrprofile zunächst auf die digitale Karte durch sogenanntes *Map-Matching* abgebildet. In diesem Prozess wird für jedes Element i des Fahrprofils ein Segment s_i im Straßennetzwerk der digitalen Karte und eine relative Position auf diesem Segment o_{s_i} im Intervall von $[0,1]$ berechnet. Unter Berücksichtigung einer Route im Straßennetzwerk (eine Folge von Segmenten

s_1, \dots, s_n) existiert eine Abbildung für jedes Tupel $(s_i, o_{s_i}) \mapsto d_i$, wobei d_i die absolute Distanz auf der Route ist und als

$$d_i = \left(\sum_{x=1}^{i-1} \text{laenge}(s_x) \right) + \text{laenge}(s_i) \cdot o_{s_i} \quad (2.1)$$

berechnet wird. In Abhängigkeit des verwendeten Positionierungssystem muss noch eine Glättung des berechneten Geschwindigkeitsverlaufs durchgeführt werden, um zu vermeiden, dass durch ungenaue Positionierung $d_i > d_{i-1}$ ist².

2.3 Datenquellen zur Filterung von Fahrprofilen

Die in dieser Arbeit vorgeschlagene Filterung von Fahrprofilen vor der wirkungsorientierten oder ursachenorientierten Analyse erfordert das Einbinden von externen Datenquellen. Zum einen werden Fahrprofile z. B. nach Tageszeit und Wochentag gefiltert, wofür die aktuelle Uhrzeit und das Datum die Datenquellen sind. Bei einer Filterung nach Verkehrslage, besonderen Verkehrsereignissen oder Wetter müssen hingegen Daten von externen Anbietern herangezogen werden.

Verkehrsdatenanbieter liefern Informationen über den aktuellen Verkehrsfluss und Verkehrsereignisse, wie z. B. Stauenden oder Sperrungen von Straßen. Beispiele dafür sind der *Inrix Traffic Service* oder *TomTom HD-Traffic*. Diese Informationen werden als Webservice im XML-Format angeboten und können periodisch abgefragt werden. Die geografischen Positionen der Verkehrsinformationen werden meistens durch den Traffic Management Code (TMC) oder Open Location Referencing (OpenLR) [Int09] kodiert. Mittels einer digitalen Karte werden diese Referenzen aufgelöst und auf das Straßennetzwerk abgebildet. Mit dieser Information können außergewöhnliche Störungen im Verkehrsfluss detektiert und daraufhin die entsprechende Datensätze aus dem Datenbestand gefiltert werden. Bei wiederkehrenden Ereignissen können diese auch verwendet werden, um aktuell relevante Datensätze zu filtern.

Wetter hat einen wesentlichen Einfluss auf das Fahrverhalten. Bei starkem Regen oder Nebel ist die gefahrene Geschwindigkeit in der Regel deutlich langsamer als bei Sonnenschein. Aus diesem Grund werden auch Wetterinformationen zur Filterung von Fahrprofilen vorgeschlagen. Insbesondere bei der wirkungsorientierten Analyse von Fahrprofilen

²Nur gültig, falls das Fahrzeug rückwärts gefahren ist. Dieser Fall wird hier jedoch zunächst ausgeschlossen, da in der Regel während der Wartezeit an einer Kreuzung nicht rückwärts gefahren wird.

wird somit verhindert, dass Fahrprofile mit positivem Wettereinfluss (z. B. durch Sonne) mit Fahrprofilen verglichen werden, die bei starkem Regen aufgezeichnet wurden. In [Leh11] werden unterschiedliche Anbieter von Wetterinformationen in Deutschland dargestellt und die Verarbeitung der Wetterdaten beschrieben.

Kapitel 3

Taktische Fahrtoptimierung

Vorausschauendes Fahren hat das Potenzial den Kraftstoffverbrauch zu reduzieren. Mit dem Ziel, das Potenzial messbar zu machen, wird in dieser Arbeit eine Kraftstoffverbrauchssimulation eingesetzt. Mit dieser ist es möglich, den absoluten Kraftstoffverbrauch für ein beliebiges Geschwindigkeitsprofil zu berechnen. Dieses Geschwindigkeitsprofil kann z. B. das Profil sein, welches von einem typischen Fahrer auf einer bestimmten Strecke gefahren wird.

Ein Ergebnis dieser Arbeit sind Algorithmen zur Berechnung der fahrbaren Maximalgeschwindigkeit auf vorausliegenden Streckenabschnitten. Ist die Maximalgeschwindigkeit bestimmt, dann kann auf dieser Basis ein Geschwindigkeitsprofil berechnet werden, für welches der Kraftstoffverbrauch minimal wird. Im Anschluss kann erneut der Kraftstoffverbrauch durch die Simulation bestimmt und mit dem Kraftstoffverbrauch für das Geschwindigkeitsprofil auf der gleichen Strecke eines typischen Fahrers verglichen werden. Die Reduzierung des Verbrauchs bezeichnen wir in dieser Arbeit als das Potenzial, den Kraftstoffverbrauch zu senken.

Im Folgenden wird der Algorithmus zur Berechnung eines verbrauchsreduzierten Geschwindigkeitsprofils in Abschnitt 3.1 vorgestellt. Anschließend beschreibt Abschnitt 3.2 die verwendete Kraftstoffverbrauchssimulation (entwickelt in der Volkswagen Konzernforschung), welche ebenfalls eine Implementierung des Algorithmus zur Berechnung von verbrauchsreduzierten Geschwindigkeitsprofilen liefert. Abschließend wird das Kraftstoffeinsparpotenzial in Abschnitt 3.3 in Beispielsituationen aufgezeigt. Diese bestehen zum einen aus Geschwindigkeitsverzögerungen bei der Zufahrt auf eine Lichtsignalanlage, zum anderen aus einem realen Geschwindigkeitsprofil, welches im Raum Wolfsburg aufgezeichnet wurde.

3.1 Berechnung eines verbrauchsreduzierten Geschwindigkeitsprofils

In diesem Abschnitt wird der in dieser Arbeit verwendete Algorithmus zur Berechnung eines *verbrauchsreduzierten* und *fahrbaren* Geschwindigkeitsprofils für ein gegebenes Geschwindigkeitsprofil vorgestellt. Hierbei ist zu erwähnen, dass das Geschwindigkeitsprofil nicht global, sondern lediglich unter Berücksichtigung einiger Einschränkungen zur Gewährleistung der Fahrbarkeit verbrauchoptimal ist. Es wird also ein Optimierungsproblem mittels einer Kostenfunktion für den Kraftstoffverbrauch unter verschiedenen Einschränkungen formuliert. Die Einschränkungen sind notwendig, um weder Verkehrsfluss noch die Sicherheit des Fahrers (z. B. durch zu langsames Fahren auf der Autobahn) zu gefährden. Naheliegende Einschränkungen sind neben den physikalischen Fahrzeugparametern z. B. die Fahrzeit, Geschwindigkeitsbegrenzungen oder der Fahrkomfort. Details werden in [SG10, DJTZ11] beschrieben.

Die Idee zur Berechnung eines verbrauchsreduzierten Geschwindigkeitsprofils ist, einen zwei-dimensionalen Lösungsraum mit Geschwindigkeit (y-Achse) und Distanz (x-Achse) aufzubauen. Initial ist die Anzahl der maximalen Elemente in diesem Raum beschränkt durch das Produkt der maximal fahrbaren Geschwindigkeit des Fahrzeugs v_{max} multipliziert mit dem Faktor der Diskretisierung der Geschwindigkeit d_v (Maximale Anzahl der Elemente pro Distanz auf der y-Achse) und der Länge des gegebenen Geschwindigkeitsprofils l_P multipliziert mit der entsprechenden Diskretisierung d_l (Maximale Anzahl der Elemente auf der x-Achse). Zusätzliche Einschränkungen, wie z. B. die minimal $v_{min,k}$ und maximal $v_{max,k}$ fahrbare Geschwindigkeit zu jeder Distanz $k \in [0, l_P]$, sind anschließend wie oben beschrieben eingeführt.

Im nächsten Schritt wird ein Graph mit Wurzelknoten $n_{k,v_{min,k}}$ unter Beachtung der Einschränkung an der Startdistanz $k = 0$ und Geschwindigkeit $v_{min,k}$ erstellt. Gegeben ist dabei eine Menge von möglichen diskreten Manövern zur Beschleunigung und Verzögerung $x_i \in X(n_{k,v_{min,k}})$ des Fahrzeugs, sodass für jeden Knoten eine neue Menge von Knoten rekursiv aufgebaut werden kann. Das Gewicht w_c der Kante beschreibt dabei die Kosten für das Manöver $f_c(x_i) = w_c$. Basierend auf diesem Graphen kann z. B. mit Dijkstras Algorithmus oder einem A*-Algorithmus der kürzeste Pfad und somit der verbrauchsreduzierte Geschwindigkeitsprofil berechnet werden. Zur Anwendung kommt diese Art der Verbrauchsreduzierung bereits im folgenden Abschnitt zur Abbildung der unterschiedlichen Fahrertypen, für welche unterschiedliche Einschränkungen gelten.

3.2 Kraftstoffverbrauchssimulation

In diesem Abschnitt wird die Kraftstoffverbrauchssimulation beschrieben, mit der das Potenzial zur Kraftstoffverbrauchsreduzierung der Algorithmen dieser Arbeit bestimmt wird. Detaillierte Beschreibungen der Simulation und der physikalischen Grundlagen sind in den Arbeiten [App08, Bar10] zu finden.

In [Bar10] werden drei Module beschrieben: Die Umwelt, der Fahrer und das Fahrzeug. Die Interaktion der Module ist in Abbildung 3.1 (angelehnt an [Bar10]) dargestellt. Die Kombination dieser Module beschreibt die Gesamtsimulation zur Bestimmung des Kraftstoffverbrauchs.

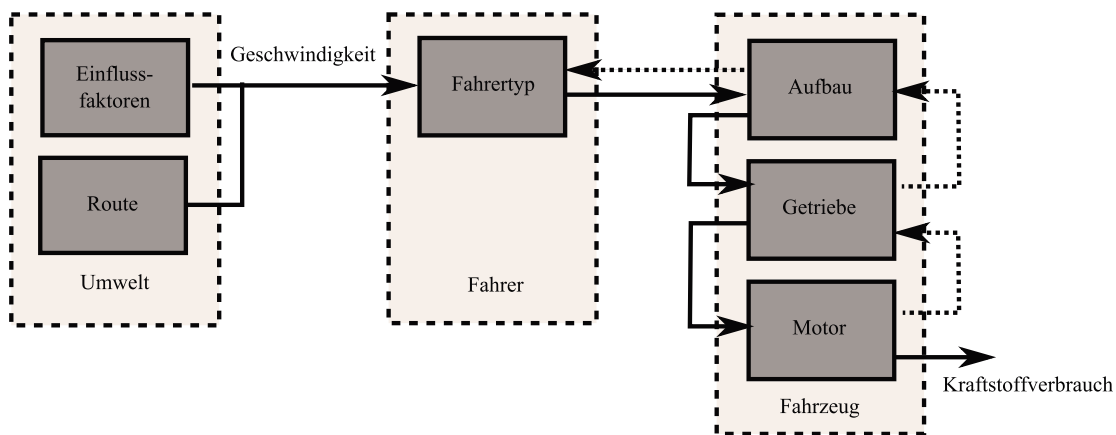


Abbildung 3.1: Aufbau der Kraftstoffverbrauchssimulation

Das Modul Umwelt beinhaltet die Route des Fahrers und die vielfältigen Einflussgrößen auf dieser Route, die bereits in Abschnitt 1.2 beschrieben wurden. Die Ausgabe dieses Moduls ist ein fahrbares Geschwindigkeitsprofil für die vorausliegende Strecke. In dieser Arbeit wird dieses Geschwindigkeitsprofil durch die entwickelten Algorithmen bereitgestellt.

Das zweite Modul bildet den Fahrstil des Fahrers ab, da dieser ebenfalls großen Einfluss auf den Kraftstoffverbrauch hat. Einen Fahrertypen zeichnet z. B. eine typische Verzögerung, Längs- und Querschleunigung aus. Häufig werden drei Fahrertypen unterschieden: Dynamisch (Sport), moderat (Normal), effizient (Eco). Die Definitionen der hier verwendeten Fahrertypen sind in [Bar10] nachzulesen.

Das dritte Modul bildet das Fahrzeug ab. Darunter fällt zunächst der Aufbau, der den Einfluss auf die Summe der Fahrwiderstände abbildet, das Getriebe und der Motor (inkl.

Nebenaggregate und Kaltstart). Dabei bilden Fahrer und Fahrzeug (gestrichelte Pfeile in Abbildung 3.1) sowie die einzelnen Komponenten des Fahrzeugmoduls jeweils einen Regelkreis. Die Ausgabe des Motors ist der Kraftstoffverbrauch für das bereitgestellte Geschwindigkeitsprofil.

Aufgrund der gegebenen Randbedingungen der Simulation durch den Fahrzeugaufbau (z. B. Leistung des Fahrzeugs) und Fahrertyp (z. B. maximale Beschleunigung) kann das gefahrene Geschwindigkeitsprofil der Simulation von dem Eingangsgeschwindigkeitsprofil abweichen. Dies tritt z. B. bei extremen Geschwindigkeitswechseln im Geschwindigkeitsprofil auf. Aus diesem Grund ist eine weitere Ausgabe der Simulation ebenfalls das durch die Simulation gefahrene Geschwindigkeitsprofil.

3.3 Kraftstoffeinsparpotenzial

Das Kraftstoffeinsparpotenzial ist die noch nicht ausgeschöpfte Möglichkeit den Kraftstoffverbrauch auf einer bestimmten Strecke unter Berücksichtigung eines gegebenen Geschwindigkeitsprofils zu senken. In diesem Abschnitt wird das Potenzial für ausgewählte Geschwindigkeitsprofile untersucht. Dabei liegt der Fokus zunächst auf einer Untersuchung der Korrelation von Zeitbedarf für das Zurücklegen der Strecke und dem Potenzial den Kraftstoffverbrauch zu reduzieren (siehe Abschnitt 3.3.1). Dabei werden Geschwindigkeitsprofile für die drei genannten Fahrertypen berechnet und anschließend der Zeitbedarf mit dem Kraftstoffverbrauch verglichen. Die Bestimmung des Potenzials wird in diesem Kapitel speziell für die in dieser Arbeit entwickelten Algorithmen durchgeführt.

Einen wesentlichen Einfluss auf das Kraftstoffeinsparpotenzial hat die Vorausschaulänge. Ein Verzögern auf der Landstraße von 100 km/h auf ein Ortseingangsschild (maximale Höchstgeschwindigkeit 50 km/h) kann z. B. deutlich effektiver mit einer großen Vorausschau (≥ 300 m) durchgeführt werden. Bei kurzer Vorausschau ist der Fahrer gezwungen zu bremsen, was in der Regel weniger effizient ist, als rechtzeitig ausrollen zu lassen und mit passender Geschwindigkeit am Ortseingangsschild anzukommen. Aus diesem Grund wird in Abschnitt 3.3.2 die Abhängigkeit des Potenzials zur Vorausschaulänge untersucht.

Die im Folgenden beschriebenen Ergebnisse wurden in dieser Arbeit auf Basis der Kraftstoffverbrauchssimulation ermittelt. Die Szenarien wurden zur Evaluierung des Potenzials der in dieser Arbeit entwickelten Algorithmen definiert und analysiert.

3.3.1 Zeitbedarf vs. Potenzial

In diesem Abschnitt wird anhand einer realen, innerstädtischen Teststrecke von 14,244 km Länge die Abhängigkeit zwischen Zeitbedarf und Potenzial zur Reduzierung des Kraftstoffverbrauchs untersucht. Zu diesem Zweck wurde die Strecke mit den drei Fahrertypen (Sport, Normal und Eco) simuliert und sowohl Kraftstoffverbrauch als auch Zeitbedarf ausgewertet.




Abbildung 3.2: Zeitbedarf vs. Kraftstoffeinsparpotenzial

Abbildung 3.2 zeigt den relativen Zeitbedarf auf der x-Achse und den relativen Kraftstoffverbrauch auf der y-Achse. Es ist zu erkennen, dass das Normal-Profil $\approx 7\%$ mehr Zeit benötigt als das Sport-Profil. Das Eco-Profil benötigt sogar $\approx 17\%$ mehr Fahrzeit. Bezogen auf den Verbrauch über der Strecke benötigt das Sport-Profil jedoch mehr Kraftstoff als die anderen Profile. In Zahlen sind das im Vergleich zum Normal-Profil $\approx 7\%$ und zum Eco-Profil $\approx 11\%$ mehr Kraftstoffverbrauch.

Übertragen auf zukünftige Fahrerassistenzsysteme zur Reduzierung des Kraftstoffverbrauchs muss also ein für den Fahrer passender Kompromiss gefunden werden. In der Regel wird dieser Kompromiss situationsabhängig getroffen und kann eventuell auch aktiv durch den Fahrer ausgewählt werden.

3.3.2 Abhängigkeit zur Vorausschaulänge

In diesem Abschnitt wird der Kraftstoffverbrauch der drei Fahrertypen (Sport, Normal, Eco) für eine Strecke von 1200 m untersucht. Zunächst beträgt dabei die Geschwindigkeit 50 km/h für die ersten 1000 m. Anschließend muss die Geschwindigkeit auf 5 km/h reduziert und so 200 m weitergefahren werden. Variiert wird dabei die Länge der Vorausschau v von 1000 m bis zu 100 m. v bezeichnet dabei die Distanz, bei der die Simulation die Information über das anstehende Manöver erhält und den Regelvorgang startet.




Abbildung 3.3: Verbrauchsreduzierte Profile bei 1000 m Vorausschau

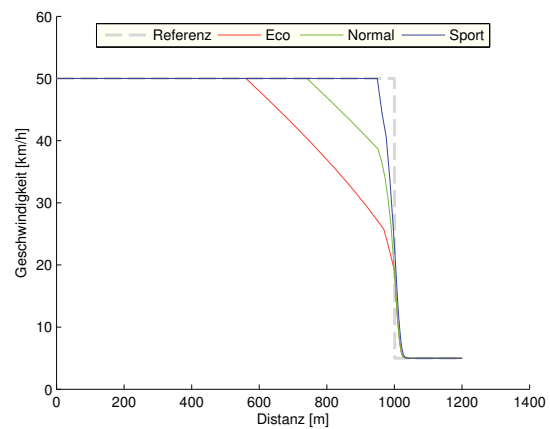


Abbildung 3.4: Verbrauchsreduzierte Profile bei 500 m Vorausschau

Abbildung 3.3 und Abbildung 3.4 zeigen die Geschwindigkeitsprofile der drei Fahrertypen und des originalen Profils für $v=1000$ m respektive $v=500$ m. Dabei ist zu erkennen, dass das Eco-Profil deutlich früher als das Normal-Profil die Geschwindigkeit verzögert, welches wiederum eher verzögert als das Sport-Profil. Weiterhin ist eine Unabhängigkeit der Geschwindigkeitsprofile von der Vorausschaulänge zu beobachten, da die Geschwindigkeitsprofile die gleiche Verzögerung durchführen. Dies lässt den Schluss zu, dass eine Vorausschaulänge von (≥ 500 m) bei einer solchen Verzögerung keinen Einfluss mehr auf den Kraftstoffverbrauch hat. Für den Innenstadtbereich, bei Geschwindigkeiten um die 50 km/h, wird also maximal eine Vorausschau von 500 m benötigt.

Im Vergleich dazu sind in Abbildung 3.5 und Abbildung 3.6 die Geschwindigkeitsprofile für $v=300$ m und $v=100$ m dargestellt. Die Verzögerung beginnt bei dieser Vorausschaulänge deutlich später, wobei noch immer das Eco-Profil als erstes und das Sport-Profil als letztes verzögert. Allerdings ist auch zu erkennen, dass die Unterschiede zwischen den Profilen kleiner werden und die Profile die Soll-Geschwindigkeit von 5 km/h bei 1000 m




Abbildung 3.5: Verbrauchsreduzierte Profile bei 300m Vorausschau




Abbildung 3.6: Verbrauchsreduzierte Profile bei 100m Vorausschau

nicht mehr erreichen können. Das ist begründet durch die Einschränkungen der maximalen Verzögerung der Fahrertypen. In Abbildung 3.6 erreicht das Eco-Profil im Vergleich zu den anderen Profilen die vorgeschriebene Geschwindigkeit als letztes. Diese Beobachtung ist auch in den Kraftstoffverbräuchen der einzelnen Geschwindigkeitsprofile zu erkennen.

Abbildung 3.7 zeigt den Kraftstoffverbrauch für die Geschwindigkeitsprofile bei unterschiedlichen Vorausschaulängen. Zunächst ist der identische Verbrauch (y-Achse) für die Vorausschaulängen 1000 m und 500 m (rote und grüne Linie, liegen übereinander) für alle Fahrertypen (x-Achse) zu erkennen, was bereits aus den Beobachtungen der Geschwindigkeitsprofile zu vermuten war. Weiterhin zeigt die Abbildung die Unterschiede der Kraftstoffreduzierung in Abhängigkeit der Vorausschaulänge für das Eco-Profil sehr deutlich. Bei den Profilen Normal und Sport ist der Verbrauch für größere Vorausschaulängen teilweise sogar größer als bei kurzer Vorausschaulänge. Dies ist begründet durch die Einschränkungen der Fahrertypen und der damit einhergehenden langsamen Verzögerung nach der Grenze von 5 km/h. Durch das Übertreten der Geschwindigkeit ab 1000 m wird eine kürzere Zeit die ineffektive Geschwindigkeit von 5 km/h gefahren und dadurch weniger Kraftstoff verbraucht.

Schlussfolgernd ist dennoch zu sagen, dass das Potenzial den Kraftstoffverbrauch zu senken bis zu einer Länge von 500 m (im Innenstadtbereich) zunimmt. Eine größere Vorausschaulänge hat keinen Einfluss mehr auf den Kraftstoffverbrauch.




Abbildung 3.7: Kraftstoffverbrauch bei unterschiedlichen Vorausschaulängen (Kraftstoffverbrauch für 1000 m und 500 m gleich)

Kapitel 4

Wirkungsorientierte Analyse von Fahrprofilen

In diesem Kapitel wird die *wirkungsorientierte Analyse* von Fahrprofilen, ein generischer Ansatz zur Analyse von Fahrprofilen ohne differenzierte Betrachtung der Einflussfaktoren auf die Geschwindigkeit, beschrieben. Die Idee hinter dieser Methode ist die Beobachtung, dass bei ähnlichen Einflussfaktoren¹ auf den meisten Streckenabschnitten nur wenige charakteristische Geschwindigkeitsverläufe existieren. Zum Beispiel existieren bei der Zufahrt auf eine Kreuzung unter der Beachtung der Rechts-vor-Links Regel zwei charakteristische Geschwindigkeitsverläufe: Ein Verlauf für den Fall, dass Vorfahrt gewährt werden muss und ein anderer Verlauf für den Fall, dass kein anderes Fahrzeug auf die Kreuzung zufährt und mit (beinahe) unverminderter Geschwindigkeit weitergefahren werden kann. Wenn die Wahrscheinlichkeiten für diese charakteristischen Geschwindigkeitsverläufe (z. B. berechnet aus historischen Fahrprofilen) bekannt sind, dann ist eine Berechnung von verbrauchseffizienten Fahrmanövern möglich.

Im Fokus dieses Kapitels stehen die Bereitstellung der charakteristischen Geschwindigkeitsverläufe und deren Wahrscheinlichkeiten ohne Kenntnis der Einflussfaktoren. Daneben wird zur Anwendung dieser Ergebnisse die Berechnung eines zukünftigen Geschwindigkeitsverlaufs (engl: Future Velocity Profile (FVP)) beschrieben, welcher der wahrscheinlichste und charakteristische Geschwindigkeitsverlauf ist. Dies wird alle paar Sekunden für die nächsten hunderte Meter im Fahrzeug berechnet. Darauf basierend wird (wie in Abschnitt 3.1 beschrieben) ein verbrauchsreduziertes Fahrprofil (engl: Fuel-Reduced Velocity Profile (RVP)) bestimmt, welches dem Fahrer angezeigt oder in einer automatisierten Längsregelung verwendet werden kann.

¹Eine Vorfilterung der Fahrprofile wird wie in Abschnitt 1.2 beschrieben vorausgesetzt.

Der in diesem Kapitel beschriebene Algorithmus ist in [KWT⁺11, KW12] veröffentlicht. Die Idee des Algorithmus wurde maßgeblich durch den Autor dieser Arbeit entwickelt. Eine erste Implementierung des Algorithmus wurde durch Holger Trompeter im Rahmen seiner Diplomarbeit durchgeführt [Tro10]. Die weiteren Koautoren haben beim Verfassen der Veröffentlichung unterstützt und auch Ideen eingebracht.

Das Kapitel ist folgendermaßen strukturiert: In Abschnitt 4.1 werden verwandte Arbeiten vorgestellt. Abschnitt 4.2 beinhaltet die Beschreibung des entwickelten Systems, wie in Abbildung 4.4 dargestellt, bestehend aus dem Dynamic Time Warping (DTW) Algorithmus in Abschnitt 4.2.1, dem Clusterverfahren in Abschnitt 4.2.2 und der Berechnung von repräsentativen Geschwindigkeitsverläufen für die Menge der Geschwindigkeitsverläufe in einem charakteristischen Geschwindigkeitsverlauf in Abschnitt 4.2.3. In Abschnitt 4.2.4 wird die Berechnung eines zukünftigen Geschwindigkeitsverlaufs als Anwendung beschrieben. Anschließend werden in Abschnitt 4.3 das vorgestellte System auf Basis von realen Fahrprofilen evaluiert, Parameterstudien durchgeführt und die Ergebnisse in Abschnitt 4.4 diskutiert und zusammengefasst.

4.1 Stand der Technik

In diesem Abschnitt wird der Stand der Technik in Bezug auf Systeme zur Reduzierung des Kraftstoffverbrauchs durch Information des Fahrers über die Geschwindigkeitseinflüsse auf dem vorausliegenden Streckenabschnitt diskutiert. Es werden Systeme beschrieben, die zum einen auf Fahrzeugsensorik und einer digitalen Karte aufbauen, aber auch auf der Fahrzeug-zu-Fahrzeug oder Fahrzeug-zu-Infrastruktur Kommunikation. Das hier vorgestellte System verwendet zum einen die Fahrzeug-zu-Infrastruktur Kommunikation zum Austauschen der Fahrprofile und zum anderen einen existierenden Algorithmus aus dem Bereich der Ähnlichkeitssuche in Zeitreihen. Im zweiten Teil dieses Abschnitts geben wir daher einen kurzen Überblick über die Algorithmen zur Zeitreihenanalyse und diskutieren deren Anwendbarkeit auf Fahrprofile.

Die Entwicklung von Assistenzsystemen zur Kraftstoffeinsparung ist schon länger im Fokus vieler Automobilhersteller und Forschungseinrichtungen weltweit. Das Potenzial der Reduzierung wird generell auf 5 % bis 20 % abhängig von der Umgebung (Straßen innerorts oder außerorts), dem Fahrertyp und der Art des Assistenzsystems geschätzt. Es wurden diverse Systeme zur Berechnung einer verbrauchsoptimalen Geschwindigkeit basierend auf der vorausliegenden Streckentopographie (z. B. [HFN06, Nie]) entwickelt. Außerdem werden Streckengeometrie und Verkehrszeichen aus einer digitalen

Karte mit in die Berechnung einbezogen [DJTZ11]. Der Nachteil dieser Systeme ist die Anforderung an aktuelle Kartendaten. Fehlerhaftes Kartenmaterial hat zur Folge, dass der Fahrer Fehlinformationen erhält und die Akzeptanz und der Nutzen der Systeme sinken. Durch Fahrzeug-zu-Infrastruktur Kommunikation werden in [KBH⁺] Verkehrsflussinformationen von vorausfahrenden Fahrzeugen genutzt, um die durchschnittliche Geschwindigkeit auf Highways zu ermitteln und daraufhin die Geschwindigkeit anzupassen. Die Autoren schätzen dabei, mit einer gegebenen Vorausschau von 10 km, den Verbrauch um bis zu 20% reduzieren zu können [KBH⁺]. Ziel der wirkungsorientierten Analyse ist es, im Vergleich zu den vorgestellten Arbeiten, ohne hochgenaue Kartendaten, allein durch das Austauschen von Fahrprofilen, eine Vorausschau über mehrere hundert Meter zu berechnen, um dadurch eine Reduzierung des Kraftstoffverbrauchs erreichen zu können. Zum Vergleich von Fahrprofilen wird Bezug auf Algorithmen zur Zeitreihenanalyse genommen.

Eine Zeitreihe ist eine Sammlung von Beobachtungen, die zeitlich sequenziell gemacht wurden. Bei diskreten Zeitreihen gibt es jeweils eine Beobachtung zu einem Zeitpunkt, wobei die Werte dabei häufig zwischen zwei Zeitpunkten interpoliert werden. In Abschnitt 2.2.3 wurde bereits die Transformation von Fahrprofilen in Geschwindigkeitsverläufe beschrieben, bei denen anschließend analog zu Zeitreihen eine Geschwindigkeit (die Beobachtung) an einer Position auf der Strecke (der Zeitpunkt) existiert.

Die Ähnlichkeitsanalyse von Zeitreihen wird in der Regel in zwei Schritten durchgeführt: Zunächst werden die Daten vorverarbeitet, um Amplitudenverschiebungen, lineare Trends, Rauschen oder Offsets zwischen Zeitreihen zu beseitigen. In Abbildung 4.1 ist die Translation des Offsets und in Abbildung 4.2 die Skalierung der Amplitude gezeigt.

Im zweiten Schritt wird das sogenannte *Matching* von Zeitreihen durchgeführt. Dabei wird die Distanz zwischen zwei gegebenen Zeitreihen berechnet und so die Ähnlichkeit bestimmt. Als Distanzmaß kommen dabei unterschiedliche Verfahren zum Einsatz. Im Folgenden werden die Einsatzgebiete der euklidischen Distanz (auch L_2 -Norm genannt), DTW und Longest Common Subsequence (LCSS) beschrieben. Bei der euklidischen Distanz wird für zwei Zeitreihen X und Y mit einer Länge von N die Distanz als $L_2(X, Y) = \sqrt{\sum_{i=1}^N |x_i - y_i|^2}$ berechnet. Das heißt, jeder Wert $x_i \in X$ wird zum gleichen Zeitpunkt mit dem Wert $y_i \in Y$ verglichen. Für Zeitreihen, die zueinander auf der X-Achse verschoben sind, liefert dieses Verfahren fehlerhafte Ergebnisse. Der DTW Algorithmus adressiert das Problem der Verschiebung zweier Zeitreihen. DTW wurde zunächst in der Spracherkennung eingesetzt [BC94], um die Ähnlichkeit von Wörtern,




Abbildung 4.1: Translation des Offsets von zwei Zeitreihen: Auf der linken Seite befinden sich zwei Zeitreihen mit einem Offset von 2,5 und auf der rechten Seite die beiden Zeitreihen nach Translation des Offsets.




Abbildung 4.2: Skalierung der Amplitude von zwei Zeitreihen: Auf der linken Seite befinden sich zwei Zeitreihen mit Offset und unterschiedlicher Amplitude, auf der rechten Seite die beiden Zeitreihen nach Translation und Skalierung des Offsets.

die unterschiedlich schnell ausgesprochen werden können, zu identifizieren. DTW benötigt als Eingabe eine $m \times n$ -Matrix, wobei der Eintrag $M_{i,j}$ die Distanz $(x_i - y_j)^2$ zwischen dem i -ten Wert von X (x_i) und dem j -ten Wert von Y (y_j) ist. Mittels dynamischer Programmierung wird anschließend der *Warping Pfad* durch M berechnet, der die Summe der Distanzen in M minimiert. DTW hat eine Komplexität von $O(N^2)$ in Zeit und Speicher, wobei $N = \max(m, n)$. Mit Ansätzen wie dem FastDTW [SC07b] kann die Komplexität jedoch auf $O(N)$ reduziert werden. Ein Vergleich zwischen euklidischer Distanz und DTW ist in Abbildung 4.3 dargestellt.

Eine Weiterentwicklung von DTW ist der LCSS-Algorithmus zur Vermeidung von Problemen bei verrauschten Zeitreihen. LCSS erlaubt dabei Lücken bei der Berechnung der Distanzen, d. h., nicht alle Werte x_i und y_i müssen auf einen Wert aus der jeweils anderen Zeitreihe abgebildet werden. Beispiele für die Anwendung von LCSS sind in [DGM97] und [VHGK03] zu finden.




Abbildung 4.3: Beispielhafter Vergleich zwischen euklidischer Distanz zweier Zeitreihen (links) und DTW (rechts)

Zum Vergleich von Fahrprofilen (Geschwindigkeitsverläufen) wird in dieser Arbeit DTW verwendet, um die Verschiebung der Fahrprofile aufgrund von unterschiedlichem Fahrverhalten bei gleichem Verkehrsereignis (z. B. Anhalten am Kreisverkehr) zu adressieren. Rauschen in Geschwindigkeitsverläufen tritt aufgrund der Trägheit der Fahrzeuge nicht auf, weswegen LCSS nicht benötigt wird. DTW wurde bereits im Fahrzeugkontext zum Vergleich von Fahrzeugtrajektorien in [ZHT06] genutzt. Allerdings ist der wesentliche Unterschied, dass hier DTW zum Vergleich von Fahrzeuggeschwindigkeit über der Distanz und nicht für 2D-Trajektorien verwendet wird.

4.2 Klassifikation und Prognose von Geschwindigkeitsverläufen

In diesem Abschnitt werden die Verarbeitungsschritte der wirkungsorientierten Analyse beschrieben. Zunächst werden die Fahrprofile dazu in Geschwindigkeitsverläufe über der zukünftigen Strecke transformiert (siehe Abschnitt 2.2.3). Anschließend wird die Route des Fahrers (z. B. bekannt aus dem Navigationssystem) in Segmente s_1, s_2, \dots, s_n der Länge $l_{s_1}, l_{s_2}, \dots, l_{s_n}$ eingeteilt. Jedem Segment werden nun aus der vorhandenen Datenbasis Teilstücke von historischen Geschwindigkeitsverläufen anderer Fahrzeuge oder vorangegangener Fahrten zugeordnet. Je kleiner dabei die Segmentgröße ist, desto größer ist die Wahrscheinlichkeit, ein Teilstück passend zu diesem Segment zu finden. Bei sehr kleinen Segmenten ist es jedoch schwierig, charakteristische Fahrmanöver in den Verläufen eines Segmentes zu identifizieren. Die Wahl der Segmentgrößen wird in Abschnitt 4.3.2.1 diskutiert. Die Erfahrungen haben dabei gezeigt, dass jedes Segment genau ein Verkehrsereignis enthalten sollte, um die Identifikation von charakteristischen Geschwindigkeitsverläufen zu erleichtern. Ein Verkehrsereignis ist dabei definiert als das Resultat einer Menge von Einflussfaktoren an einer Position, welche eine wiederkehrende

Veränderung der Geschwindigkeit in mehreren Profilen, wie z. B. einer Rechts-vor-Links Situation, zur Folge hat. Die nachfolgenden Verarbeitungsschritte zur Berechnung des zukünftigen Geschwindigkeitsverlaufs sind in Abbildung 4.4 dargestellt.

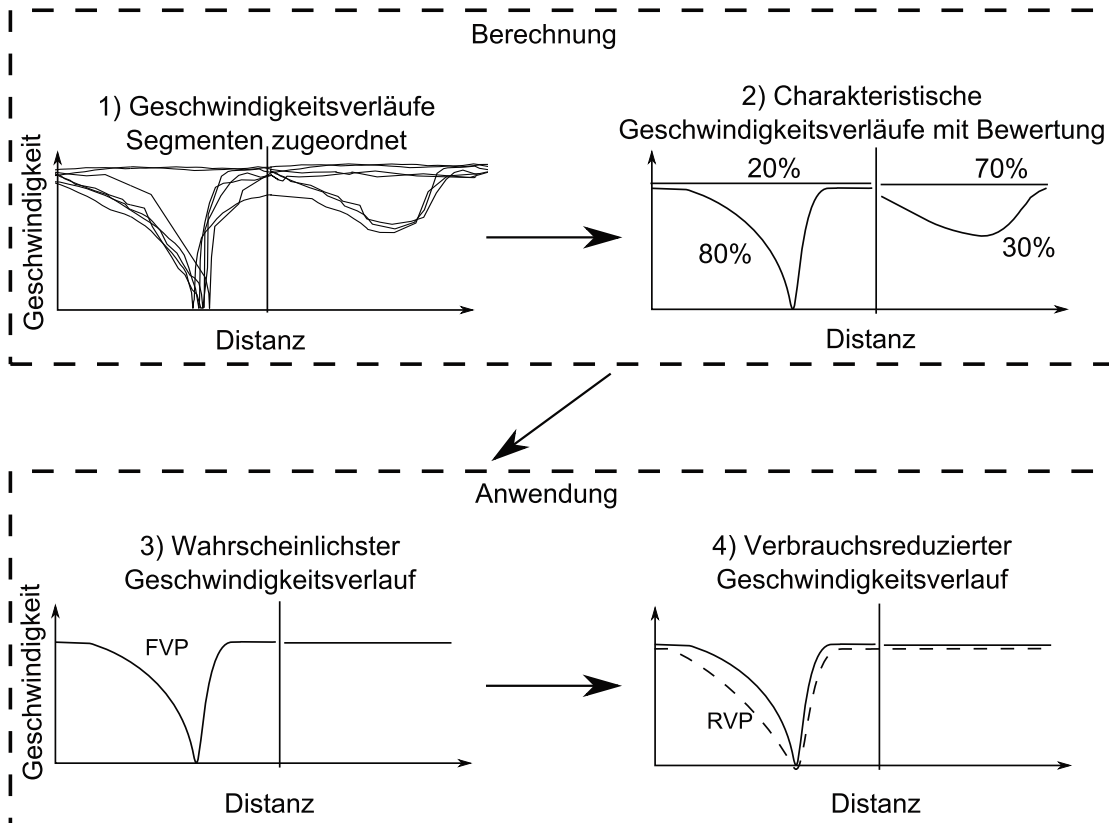


Abbildung 4.4: Prozess der Berechnung charakteristischer Geschwindigkeitsverläufe mittels wirkungsorientierter Analyse und Anwendung zur Bestimmung des zukünftigen und verbrauchsoptimierten Geschwindigkeitsverlaufs.

Im ersten Schritt wird jedem Segment s_i eine Menge von verfügbaren Geschwindigkeitsverläufen P_s zugeordnet. Wobei alle $p \in P_s$ Folgen von (Geschwindigkeit, Distanz)-Paaren sind (siehe Abschnitt 2.2.3).

Im zweiten Schritt werden charakteristische Geschwindigkeitsverläufe $c_1, c_2, \dots, c_n \in C_i$ aus der Menge aller Geschwindigkeitsverläufe jedes Segmentes $s_i \in S$ mittels Clusterverfahren berechnet. Das Problem bei dieser Klassifizierung ist die Wahl eines geeigneten Abstandsmaßes für Geschwindigkeitsverläufe. Veränderungen in der Geschwindigkeit aufgrund gleicher Einflussfaktoren an einer ähnlichen Position (ein Verkehrereignis) sind in Geschwindigkeit und/oder Distanz zueinander verschoben. Dies resultiert zum einen aus unterschiedlichem Verhalten von Fahrern, aber auch aus der Verschiebung der Posi-

tion von Einflussfaktoren (wie z. B. bei einem Rückstau). Ziel ist es, ein Distanzmaß zu finden, welches trotz der Verschiebung von Geschwindigkeitsverläufen die Ähnlichkeit in der Form erkennt. Zu diesem Zweck wird DTW als Distanzmaß verwendet (siehe Abschnitt 4.2.1). Nach der Klassifizierung der Geschwindigkeitsverläufe (Abschnitt 4.2.2) wird für jede Klasse ein repräsentativer Geschwindigkeitsverlauf (Abschnitt 4.2.3) bestimmt.

Im dritten Schritt (der Anwendung) wird das FVP beginnend an der aktuellen Fahrzeugposition berechnet. Für die Reststrecke im aktuellen Segment wird mit Hilfe von DTW der aktuelle Geschwindigkeitsverlauf des Fahrzeugs dem ähnlichsten charakteristischen Geschwindigkeitsverlauf zugeordnet und dann das FVP als repräsentativer Geschwindigkeitsverlauf dieser Klasse bestimmt. Abhängig von der Position des Fahrzeugs und der Segmentlänge kann die restliche Distanz im aktuellen Segment gering sein, sodass eine Berechnung des FVP über mehrere Segmente notwendig ist, um einen verbrauchseffizienten Geschwindigkeitsverlauf mit größerer Vorausschau berechnen zu können (siehe Abschnitt 3.3.2). Dazu wird iterativ der charakteristische Geschwindigkeitsverlauf auf dem nächsten Segment mit der höchsten Wahrscheinlichkeit w berechnet. Dabei ist die Wahrscheinlichkeit der Quotient der Anzahl der Fahrzeuge dieser Klasse und der Anzahl aller Fahrzeuge, die auf dem aktuellen Segment in der wahrscheinlichsten Klasse waren.

Im vierten Schritt wird das RVP mittels einer Kostenfunktion für mögliche Fahrmanöver berechnet, wie in Abschnitt 3.1 beschrieben.

4.2.1 Dynamic Time Warping als Distanzmaß

Das Ziel ist, ein Distanzmaß zu finden, welches zwei Geschwindigkeitsverläufe als ähnlich beurteilt, wenn sie unter Einfluss des gleichen Verkehrereignisses (z. B. eines Bremsvorgangs aufgrund einer bevorstehenden Kurvendurchfahrt) entstanden sind. Ein naives Distanzmaß wäre die Summe aller Geschwindigkeitsunterschiede von zwei Profilen über der Strecke (L_p -Norm). Allerdings würde dieses Distanzmaß bei leicht zueinander verschobenen Profilen schon eine große Unähnlichkeit feststellen.

Die Verschiebung von Geschwindigkeitsverläufen in Distanz (x-Achse) und/oder Geschwindigkeit (y-Achse) bei gleichem Verkehrereignis können in realen Profilen beobachtet werden (siehe Abbildung 4.5). Gründe dafür können die Verkehrsdichte (z. B. bei einem Stopp an einer Haltelinie in erster, zweiter oder dritter Position), Unterschiede




Abbildung 4.5: Verschiebung realer Geschwindigkeitsprofile an einer Kreuzung

zwischen sportlichen und ökonomischen Fahrern oder auch ungenaue Positionsbestimmung der Fahrzeuge sein. Daher wird ein Distanzmaß, welches diese Verschiebungen berücksichtigt und die Ähnlichkeit zweier Profile anhand ihrer Form beurteilt, gesucht. DTW [BC94, Keo02, SC07a] ist ein Distanzmaß in der Spracherkennung, in welcher ein vergleichbares Problem existiert: Personen sprechen die gleichen Worte mit unterschiedlicher Geschwindigkeit aus.

Mit DTW wurde in dieser Arbeit ein Distanzmaß für Geschwindigkeitsverläufe $p_x, p_y \in P_s$ mit der Länge $m, n \in \mathbb{N}$ identifiziert.² Der erste Schritt bei der Berechnung [Keo02] ist der Aufbau einer $m \times n$ -Matrix $M_{i,j}$, wobei das (i, j) -te Element der Matrix die Distanz $d(v_{x_i}, v_{y_j})$ zwischen den beiden Elementen v_{x_i} und v_{y_j} ist:

$$M_{i,j} = d(v_{x_i}, v_{y_j}) \quad (4.1)$$

Die Distanz wird dabei als $d(v_{x_i}, v_{y_j}) = (v_{x_i} - v_{y_j})^2$ berechnet.

Darauf basierend ist der *Warping Path* W als kontinuierliche Folge von Elementen der Matrix definiert, welche die Verschiebung der Verläufe p_x and p_y definiert. Das Element

²Für sehr kurze Segmente und hohe Geschwindigkeiten können die Verläufe aus nur wenigen Messungen pro Segment bestehen, wodurch die Berechnung verschlechtert wird. Dieses Problem kann jedoch durch Interpolation zwischen den Elementen bzw. der Verwendung von Continuous DTW [MP99] umgangen werden.

k aus W ist dabei definiert als:

$$w_k = (i, j)_k \quad (4.2)$$

Aus Gleichung 4.2 folgt:

$$W = w_1, w_2, \dots, w_k, \dots, w_K \quad \max(m, n) \leq K < m + n - 1 \quad (4.3)$$

Dabei unterliegt W den folgenden Bedingungen:

- **Randbedingung:** $w_1 = (1, 1)$ und $w_K = (m, n)$. Diese Bedingung erfordert, dass der *Warping Path* in der linken oberen Ecke startet und in der rechten unteren Ecke der Matrix endet.
- **Stetigkeit:** Gegeben ist $w_k = (a, b)$, dann muss $w_{k-1} = (a', b')$ wobei $a - a' \leq 1$ und $b - b' \leq 1$ gilt. Dies begrenzt die Schritte von W auf benachbarte (auch diagonale) Zellen.
- **Monotonie:** Gegeben ist $w_k = (a, b)$, dann muss $w_{k-1} = (a', b')$ wobei $a - a' \geq 0$ und $b - b' \geq 0$. Diese Bedingung fordert ein monotonen Wachsen von W .

Auf der Menge aller W ist der optimale Pfad DTW definiert durch

$$DTW(v_x, v_y) = \min \left\{ \sum_{k=1}^{k=K} w_k \right\}. \quad (4.4)$$

Um diesen in der Menge aller Pfade zu finden, wird ein rekursiver Durchlauf durch M gestartet. Beim Rekursionsaufbau wird die Kostenmatrix M berechnet. Beim Abbau der Rekursion wird die kumulative Distanz $\gamma(i, j)$, wie durch Gleichung 4.5 angegeben, berechnet.

$$\gamma(i, j) = d(v_{x_i}, v_{y_j}) + \min \{ \gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1) \} \quad (4.5)$$

Darauf basierend wird für jedes Segment s der vorausliegenden Route eine symmetrische Distanzmatrix M_{dtw} mit $M_{dtw}(x, y) = DTW(p_x, p_y) \forall p_x, p_y \in P_s$ mit $0 < x, y \leq |P_s|$ konstruiert, wobei das Element an Position (x, y) die DTW Distanz des x -ten und y -ten Geschwindigkeitsverlaufs des Segments s ist. Diese Matrix ist anschließend das Eingangsdatum für den Clusteralgorithmus.

4.2.2 Berechnung charakteristischer Geschwindigkeitsverläufe

Ist die Distanzmatrix M_{dtw} gegeben, können nun die Cluster der Geschwindigkeitsverläufe auf jedem Segment berechnet werden. Dazu wird ein agglomeratives hierarchisches Clusterverfahren verwendet, wobei die Anzahl der entstehenden Cluster vorher nicht bekannt ist. Aus diesem Grund wird zunächst $n = 1$ mittels Complete-Linkage [DE84] berechnet und im nächsten Schritt überprüft, ob die maximale Distanz zwischen zwei beliebigen Geschwindigkeitsverläufen in jedem Cluster größer als ein Schwellenwert T ist. Ist dies gegeben, dann werden $n = n + 1$ Cluster berechnet und die Schwellenwertprüfung erneut durchgeführt. Dies wird so lange fortgeführt, wie die Distanz zweier Profile in einem Cluster größer als T ist. Für jedes Segment $s_i \in S$ liefert der Clusteralgorithmus eine Menge von Clustern $c_1, c_2, \dots, c_n \in C_i$, wobei jedes eine Menge von Geschwindigkeitsverläufen enthält.

Im nächsten Schritt wird das Fahrzeug, in welchem die Berechnung stattfindet, einem entstanden Cluster auf dem aktuellen Segment s_1 zugewiesen. Dazu wird der aktuell gefahrene Geschwindigkeitsverlauf mit dem *repräsentativen* Verlauf r_{c_j} jedes Clusters c_j verglichen und die Prognose der Geschwindigkeit auf Basis des ähnlichsten repräsentativen Geschwindigkeitsverlaufs durchgeführt. Im nächsten Abschnitt wird nun zunächst die Berechnung des repräsentativen Geschwindigkeitsverlaufs beschrieben.

4.2.3 Berechnung des repräsentativen Geschwindigkeitsverlaufs

In diesem Abschnitt wird die Berechnung des repräsentativen Geschwindigkeitsverlaufs für ein Cluster $c \in C_x$ beschrieben. Aufgrund der Verschiebung von Geschwindigkeitsverläufen in Distanz und Geschwindigkeit kann aus einer naiven Berechnung, wie z. B. als mittlere Geschwindigkeit aller Verläufe über der Strecke, ein nicht fahrbarer bzw. nicht realistischer, repräsentativer Verlauf resultieren. Beispielhaft ist der Fehler in Abbildung 4.6 dargestellt. Daher wird in dieser Arbeit vorgeschlagen, die Geschwindigkeitsverläufe in c über der Distanz in der Art zu verschieben, dass die Summe der euklidischen Distanzen minimal wird. Mit den verschobenen Geschwindigkeitsverläufen wird anschließend die mittlere Geschwindigkeit aller Verläufe an jedem Ort berechnet, wie im Folgenden beschrieben.

Die Verschiebung s von zwei Profilen $p_x, p_y \in c$ der Länge $n \in \mathbb{N}$, welche die Summe der euklidischen Distanzen minimiert, wird nach Gleichung 4.6 berechnet:

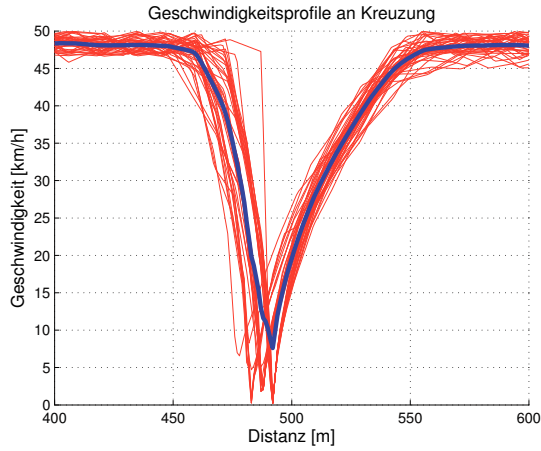


Abbildung 4.6: Geschwindigkeitsverläufe ohne Verschiebung eines Clusters und daraus resultierendes mittleres Profil m_1 (blaue Linie)

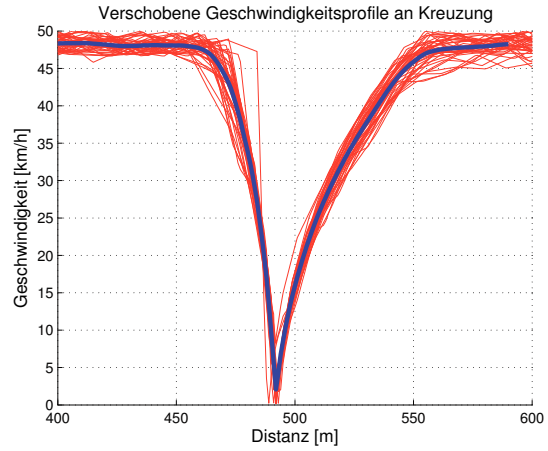


Abbildung 4.7: Geschwindigkeitsverläufe mit Verschiebung eines Clusters und daraus resultierendes mittleres Profil m_2 (blaue Linie)

$$\arg \min_{s \in [-n/2, n/2]} \sum_{i=1}^n (p_{x_i} - p_{y_j})^2$$

$$\text{mit } j = \begin{cases} i + s, & \text{if } 0 < i + s \leq n \\ (i + s) + n, & \text{if } i + s \leq 0 \\ (i + s) - n, & \text{if } i + s > n \end{cases} \quad (4.6)$$

Die Verschiebung aller Geschwindigkeitsverläufe in c wird daraufhin in den folgenden Schritten berechnet: Zuerst wird ein zufälliger Verlauf p_r ausgewählt und die Verschiebung zu allen anderen Geschwindigkeitsverläufen in dem Cluster (inklusive p_r selbst) berechnet. Sei die Menge $S_{p_r} = \{s_1, s_2, \dots, s_{|c|}\}$ das Ergebnis, dann wird im zweiten Schritt die durchschnittliche Verschiebung von p_r als $s_{avg} = avg(S_{p_r})$ berechnet. Anschließend wird im dritten Schritt die absolute Verschiebung für jeden Geschwindigkeitsverlauf p_i als $s_{abs_i} = s_i - s_{avg}$ bestimmt und viertens der repräsentative Verlauf $r(c)$ als mittlere Geschwindigkeit aller verschobenen Geschwindigkeitsverläufe an jedem Ort berechnet. Das Ergebnis nach der Verschiebung ist in Abbildung 4.7 dargestellt.

4.2.4 Prognose des zukünftigen Geschwindigkeitsverlaufs

Unter Verwendung der berechneten Cluster in Abschnitt 4.2.2 und der repräsentativen Geschwindigkeitsverläufe 4.2.3 wird das FVP wie folgt berechnet: Zunächst wird das aktuelle Cluster für das Segment, auf dem das Fahrzeug sich aktuell bewegt (s_1), durch die Berechnung von $\min(DTW(p, r(c_j)))$ bestimmt, wobei p der aktuelle Geschwindigkeitsverlauf des Fahrzeugs und $r(c_j)$ der repräsentative Geschwindigkeitsverlauf des Clusters $c_j \in C_1$ des aktuellen Segments ist. Ohne Beschränkung der Allgemeinheit wird angenommen, dass der Geschwindigkeitsverlauf $r(c_1)$ die größte Ähnlichkeit aufweist. Das heißt, der zukünftige Geschwindigkeitsverlauf bis zum Ende des Segments s_1 entspricht $r(c_1)$.

Die Distanz bis zum Ende von s_1 kann sehr kurz sein. Um eine größere Vorausschau erreichen zu können, wird der zukünftige Geschwindigkeitsverlauf über den nächsten k Segmenten vorausberechnet. Dabei entspricht der zukünftige Verlauf dem repräsentativen Verlauf des wahrscheinlichsten Clusters auf dem vorausliegenden Segment.³

Es existiert analog zu s_1 eine Menge von Clustern mit zugehörigen Geschwindigkeitsverläufen für jedes vorausliegende Segment. D. h., das nächste Segment (s_2) hat die Cluster $d_1, d_2, \dots, d_m \in C_2$. Für jedes dieser Cluster $d_x, x \in 1, \dots, m$ wird die Eintrittswahrscheinlichkeit w in Abhängigkeit des aktuellen und einer bestimmten Anzahl an vorherigen Clustern berechnet. Dabei wird die Wahrscheinlichkeit $w(h, d_x)$ als Quotient aus Fahrzeugen bestimmt, die eine gleiche Historie (die gleichen Cluster auf der zurückliegenden Strecke) hatten und anschließend Cluster d_x gefahren sind. Im Folgenden wird W als die Menge aller Übergangswahrscheinlichkeiten zwischen den Clustern bezeichnet.

Angenommen d_1 ist das Cluster mit der höchsten Wahrscheinlichkeit, dann ist $r(d_1)$ der repräsentative Geschwindigkeitsverlauf für Ego-Fahrzeug (das Fahrzeug, in welchem die Berechnung durchgeführt wird) für das Segment s_2 . Zur Prädiktion des zukünftigen Geschwindigkeitsverlaufs für s_3 wird der oben beschriebene Algorithmus mit d_1 als das aktuelle Cluster wiederholt und die Übergangswahrscheinlichkeiten in Cluster aus C_3 berechnen. Auf diese Weise wird bis zum Segment s_k der zukünftige Geschwindigkeitsverlauf berechnet. Ein wesentlicher Parameter dieses Algorithmus ist die Anzahl a der zurückliegenden Cluster mit Einfluss auf die Übergangswahrscheinlichkeit. Die Wahl des Parameters a wird anhand einer Analyse von Realdaten in Abschnitt 4.3.2.4

³Für den Fall, dass zwei Cluster eine ähnliche Wahrscheinlichkeit aufweisen, muss in Abhängigkeit des Anwendungsfalls entschieden werden, ob eine Entscheidung für ein Cluster getroffen wird oder keine Prognose durchgeführt werden kann.

durchgeführt. Im Folgenden ist der beschriebene iterative Prozess in Algorithmus 1 dargestellt.

Algorithmus 1: Berechnung des zukünftigen Geschwindigkeitsverlaufs

Eingabe : C = Cluster des aktuellen und der vorausliegenden Segmente, p_{ego} = Ego-Fahrprofil, k = Anzahl der Segmente zur Vorausschau, a = Anzahl der zu betrachtenden zurückliegenden Cluster

Ausgabe : $g_1, g_2 \dots, g_{|C|}$ = Folge von repräsentativen Geschwindigkeitsverläufen

```

1  $idx$  = Finde den repräsentativen Geschwindigkeitsverlauf  $r(c_i)$  (wobei  $c_i \in C_1$ ) mit
   kleinsten Distanz zu  $p_{ego}$  mittels DTW;
2  $g_1 = r(c_{idx})$ ;
3 Setze Geschwindigkeitsverläufe  $P = p_1, p_2, \dots, p_m$  gleich der Verläufe aus  $c_{idx}$ ;
4 for  $i = 2; i \leq |C| \wedge i \leq k; i++$  do
5   | Allokiere Speicher für Wahrscheinlichkeiten  $W = w_1, w_2, \dots, w_{|C_i|}$ ;
6   | foreach  $c_j \in C_i$  do
7   |   | Berechne die Schnittmenge  $s_{ids}$  der Fahrzeug IDs aus  $c_j$  und der
   |   | zurückliegenden  $a$  Cluster;
8   |   | Setze die Übergangswahrscheinlichkeit  $w_j = \frac{|s_{ids}|}{|P|}$ ;
9   | end
10  | Finde Index  $idx_w = \max(W)$ ;
11  | Aktuelles Cluster  $c_{akt} = c_{idx_w} \in C_i$ ;
12  | Setze Geschwindigkeitsverlauf  $g_i = r(c_{akt})$ ;
13  | Setze Verläufe  $P = p_1, p_2, \dots, p_{|c_{akt}|}$  gleich der Verläufe aus  $c_{akt}$ ;
14 end

```

Die Folge der repräsentativen Geschwindigkeitsverläufe für die Segmente s_1, s_2, \dots, s_k ist dann das FVP unter Berücksichtigung der aktuellen Fahrzeuggeschwindigkeit.

4.3 Evaluierung des Algorithmus

In diesem Abschnitt wird zunächst die Durchführung der Messfahrten beschrieben. Dabei liegt der Fokus auf der Fahrtstrecke sowie dem verwendeten Fahrzeug und der Messhardware (siehe Abschnitt 4.3.1). Anschließend werden schrittweise die Verarbeitung der Messdaten, die Bestimmung der Algorithmusparameter und die Ergebnisse der einzelnen Verarbeitungsschritte in Abschnitt 4.3.2 beschrieben. Die Verarbeitungsschritte sind die Berechnung der charakteristischen Geschwindigkeitsverläufe, die Prognose des FVP und die Bestimmung des Potenzials, den Kraftstoffverbrauch auf der ausgewählten Messstrecke zu reduzieren.

4.3.1 Experimentdurchführung

Als Messstrecke wurde eine Route gewählt, die eine Teilstrecke Landstraße und eine Teilstrecke Stadtverkehr beinhaltet. Abbildung 4.8 gibt einen Überblick über die gefahrene Strecke (Rundkurs gegen den Uhrzeigersinn gefahren). In Tabelle 4.1 sind die wesentlichen Routeninformationen dargestellt.



Abbildung 4.8: Ausgewählte Messstrecke [Goo].

Details der Messstrecke	
Rundkurs Länge	15,072 m
Erlaubte Maximalgeschwindigkeit (absolut)	70 $\frac{\text{km}}{\text{h}}$
Durchschnittsgeschwindigkeit	40,25 $\frac{\text{km}}{\text{h}}$
Durchschnittliche Fahrtdauer (zehn Fahrten)	28 Min. 23 Sek.
Durchschnittlicher Kraftstoffverbrauch	5,89 $\frac{\text{l}}{100\text{km}}$

Tabelle 4.1: Informationen zur gewählten Messstrecke.

Die Messfahrten wurden mit einem VW Golf VI durchgeführt. Die technischen Daten des Fahrzeugs sind in Tabelle 4.2 aufgeführt.

Die Fahrprofile wurden mit Hilfe eines U-blox 5H [ubAa] GPS-Empfängers und einem Zugang zum CAN-Bus des Fahrzeugs aufgezeichnet und gespeichert. Die technischen Details des Empfängers sind in Tabelle 4.3 dargestellt. Die Geschwindigkeit des Fahrzeugs wurde aufgrund der höheren Genauigkeit, Verfügbarkeit und Frequenz vom CAN-Bus genommen.

Die Teststrecke wurde an verschiedenen Tagen insgesamt zehn Mal am Vormittag gefahren und die Daten wurden aufgezeichnet. Eine Filterung der Daten ist nicht notwendig,

Fahrzeugeigenschaften	
Motor-Bauart	4-Zylinder
Hubraum [cm^3]	1968
Max. Leistung [kW(PS)] bei 1/min	103(140) / 4200
Getriebevariante	6-Gang Doppelkupplungsgetriebe DSG
Leergewicht [kg]	1397
Kraftstoffart	Diesel

Tabelle 4.2: Technische Daten des Messfahrzeugs

GPS Empfänger	
Typ	5H
Unterstützte Systeme	GPS, GALILEO
Anschlüsse	USB 2.0 und RS-232
Stromversorgung	USB
Aktualisierungsfrequenz	1 Hz

Tabelle 4.3: Eigenschaften des verwendeten u-blox Empfängers

da bereits bei der Durchführung der Messungen auf die Randbedingungen (z. B. Wetter) geachtet wurde.

4.3.2 Ergebnisse

In diesem Abschnitt werden Ergebnisse der einzelnen Berechnungsschritte aus der Verarbeitungskette des Systems dargestellt. Zunächst wird die Wahl der Segmentgröße s und Grenzwert T für das Clusterverfahren mittels DTW diskutiert. Daraufhin werden die Berechnung der charakteristischen Geschwindigkeitsverläufe über der Messstrecke beschrieben und die segmentübergreifende Prognose des Geschwindigkeitsverlaufs untersucht. Dabei wird ebenfalls die Bestimmung des Parameters a , der Anzahl der zurückliegenden Streckensegmente mit Einfluss auf das FVP, beschrieben, um abschließend das Potenzial der Kraftstoffeinsparung für die Messstrecke zu analysieren.

4.3.2.1 Wahl der Segmentgröße

Zur Bewertung von historischen Fahrprofilen auf einer Strecke wird diese zunächst in Streckenabschnitte, sogenannte Segmente, unterteilt. Für jedes dieser Segmente wird anschließend die Ähnlichkeit der zugehörigen Fahrprofile berechnet und deren Eintrittswahrscheinlichkeit berechnet. Je größer dabei die Segmente sind, z. B. ein Segment für die

gesamte Fahrt über mehrere Kilometer, desto größer ist die Unähnlichkeit der einzelnen Fahrprofile. Dies ist bedingt durch die Vielzahl an Brems- und Beschleunigungsvorgängen, welche selten auf einer langen Strecke ähnlich sind. Bei sehr kleinen Segmenten (z. B. $s \leq 50 \text{ m}$) hingegen ist die Wahrscheinlichkeit sehr hoch, im Geschwindigkeitsverlauf ähnliche Fahrprofile zu finden. Leider sind dabei wiederkehrende Muster in den Geschwindigkeitsverläufen aufgrund von gleichen Verkehrseinflüssen nicht mehr erkennbar, da sich diese meistens über mehrere 100 m erstrecken. Die Aufgabe ist nun eine Segmentierung zu finden, welche die Erkennung *einzelner* Muster (Verkehrereignisse) erlaubt. Es entstehen daraus zwei Fragen: An welchen Positionen auf der Strecke dürfen Segmentübergänge sein? Wie groß sollten Segmente sein?

Ein naiver Ansatz zur Segmentierung ist das Aufteilen der Strecke in Segmente gleicher Größe ($s = \text{const}$). Dabei kann es jedoch passieren, dass Verkehrereignisse geteilt und die Geschwindigkeitsverläufe nicht mehr wie gewünscht klassifiziert werden. Ein Beispiel dafür ist in Abbildung 4.9 auf der linken Seite gegeben. Auf der rechten Seite hingegen ist eine Segmentierung der Situation gezeigt, die das gesamte Verkehrereignis einschließt. Beide Abbildungen zeigen genau ein Segment der Länge 200 m, wobei das Ereignis in der linken Abbildung auf zwei Segmente aufgeteilt wird (das Anfahren einiger Fahrzeuge ist im nächsten Segment) und auf der rechten Seite in ein Segment fällt.




Abbildung 4.9: Darstellung eines Segments mit fester Segmentgröße (links, hier: $s=200 \text{ m}$) bei Teilung eines Verkehrereignisses und Segmentierung mit variabler Segmentgröße $s \geq 200 \text{ m}$ (rechts)

Zur Generierung der Segmentierung auf der rechten Seite werden Bedingungen an die Position der Segmentgrenzen gestellt. Dabei muss jede Segmentgrenze $g_i \in G$ die folgenden Bedingungen erfüllen:

1. Die Position der Segmentgrenze g_i muss mindestens x_{min} -Meter Abstand zur Position der Segmentgrenze g_{i-1} haben ($g_i \geq g_{i-1} + x_{min}$).
2. Die Geschwindigkeitsdifferenz d aller Fahrprofile p an der Position von g_i darf den Grenzwert y nicht überschreiten. Dadurch wird sichergestellt, dass kein Verkehrsereignis (erkennbar durch große Unterschiede der Geschwindigkeit einzelner Fahrprofile) an dieser Position auftritt.
3. Die Geschwindigkeitsdifferenz d aller Fahrprofile p an der Position von g_i muss ein Minimum der Geschwindigkeitsdifferenzen sein. D. h., vor und nach der Position von g_i müssen die Geschwindigkeitsdifferenzen größer als an der Position g_i sein.
4. Die minimale Geschwindigkeit an der Position g_i muss größer als der Grenzwert der Geschwindigkeit z sein. Dies stellt sicher, dass Segmentgrenzen nur bei größeren Geschwindigkeiten liegen und nicht an einer Position, an der alle Fahrzeuge halten müssen. Denn dadurch würde erneut das Ereignis geteilt werden.
5. Die Position der Segmentgrenze g_i soll maximal x_{max} -Meter Abstand zur Position der Segmentgrenze g_{i-1} haben. Diese Bedingung limitiert die Segmentgröße, falls Bedingungen 2) - 4) dies erlauben. Segmente können jedoch aufgrund der anderen Bedingungen (die nicht verletzt werden dürfen) größer sein.

In Abbildung 4.9 (rechts) entsteht mittels dieser Randbedingungen der Segmentierung ein fast 400 m großes Segment, welches ein vollständiges Verkehrsereignis enthält. Die Geschwindigkeitsverläufe sind dabei in zwei Cluster eingeteilt (unterschiedliche Farbgebung). Ohne Randbedingungen mit fester Segmentbreite ist das Verkehrsereignis in zwei Segmente geteilt worden und es sind vier Cluster entstanden. In der rechten Abbildung erkennt DTW, dass alle Geschwindigkeitsverläufe bis auf ein Profil eine Reduzierung der Geschwindigkeit beinhalten und anschließend wieder beschleunigen. In der linken Abbildung ist dies nicht möglich, da der Beschleunigungsvorgang nicht von allen Profilen vollständig zu erkennen ist. Somit unterscheiden sich die Profile in ihrem Muster und sind in unterschiedliche Cluster eingeteilt. Als Konsequenz werden in dieser Arbeit variable Segmentgrößen mit den oben genannten Randbedingungen verwendet. Es stellt sich nun die Frage, welche Segmentgrößen für die hier gewählte Messstrecke passend sind.

Zur Beantwortung dieser Frage wurden verschiedene Parameter miteinander verglichen. Hier dargestellt ist beispielsweise der Vergleich von $x_{min} = 1000\text{ m}$ und $x_{max} = 1200\text{ m}$ mit den bereits beschriebenen Segmentgrenzen $x_{min} = 200\text{ m}$ und $x_{max} = 300\text{ m}$. Die

Geschwindigkeitsdifferenz und die Grenze für die minimale Geschwindigkeit sind hier identisch.




Abbildung 4.10: Oben: Ein Segment mit zwei Verkehrseignissen bei variabler Segmentgröße (hier: 1000 – 1200 m). Unten: Entsprechende Segmente für die beiden Verkehrseignisse bei variabler Segmentgröße von 200 – 300 m

In Abbildung 4.10 ist das Ergebnis der beiden Konfigurationen dargestellt. Oben ist ein Segment mit einer Größe von knapp über 1000 m zu sehen, welches zwei Verkehrseignisse beinhaltet. Daraus resultieren zwei Cluster: Das erste Cluster beinhaltet alle Geschwindigkeitsverläufe mit einer Geschwindigkeitsreduzierung und das zweite Cluster alle Geschwindigkeitsverläufe mit zwei Geschwindigkeitsreduzierungen auf dem Segment. In dem ersten Cluster wird dabei nicht zwischen dem ersten und zweiten Verkehrseignis unterschieden. Als Konsequenz aus dieser Klassifikation kann lediglich auf die Wahrscheinlichkeit für einen oder für zwei Stopps geschlossen werden, jedoch nicht, an welchem Verkehrseignis gehalten werden muss. Bei einer Segmentgröße von 200 m bis 300 m entstehen auf gleicher Strecke drei Segmente. Die zwei Segmente, welche die

Parameter	Wert
Minimale Segmentbreite	$x_{min} = 200$ m
Maximale (geforderte) Segmentbreite	$x_{max} = 300$ m
Maximale Geschwindigkeitsdifferenz aller Profile	$y = 15$ km/h
Zu unterschreitende Geschwindigkeit eines Profils	$z = 30$ km/h

Tabelle 4.4: Parameter der Segmentierung

Verkehrereignisse umfassen, sind in Abbildung 4.10 unten dargestellt. Das Segment in der Mitte besteht aus nur einem Cluster aller Geschwindigkeitsverläufe und ist daher hier nicht dargestellt. Die beiden Verkehrereignisse sind bei dieser Segmentgröße vollständig in einem Segment und der Clusteralgorithmus kann zwischen Verläufen mit Geschwindigkeitsreduzierung und Verläufen mit konstanter Geschwindigkeit unterscheiden. Aus diesem Grund wird im Folgenden die hier beschriebene Konfiguration (siehe auch Tabelle 4.4) zur Detektion von Segmenten verwendet.

4.3.2.2 Grenzwert zur Identifikation von Clustern mittels DTW

Nach Aufteilung der Strecke in Segmente muss ein geeigneter Grenzwert T für den hierarchischen Clusteralgorithmus festgelegt werden. Dabei beeinflusst T ganz wesentlich die Anzahl der resultierenden Cluster pro Segment. Der Grenzwert gibt die maximale Distanz (berechnet mit DTW) zwischen zwei Profilen eines Clusters an. Für den Fall, dass die Distanz den Grenzwert überschreitet, wird die Anzahl der zu berechnenden Cluster um eins erhöht und der hierarchische Clusteralgorithmus erneut gestartet.

Die Distanz zweier Geschwindigkeitsverläufe X und Y mit DTW ist abhängig von der Länge K des Warping Pfades, welcher durch die Länge des Segmentes und die Verschiebung der Geschwindigkeitsverläufe zueinander beeinflusst wird. Die Distanz $DTW(X, Y)$ entspricht (siehe Abschnitt 4.2) $DTW(X, Y) = \min \sum_{k=1}^{k=K} w_k$, wobei w_k der quadratischen Distanz zweier Werte aus den Geschwindigkeitsverläufen entspricht. Die Länge des Warping Pfades K ist unterschiedlich für die DTW Distanz unterschiedlicher Geschwindigkeitsverläufe auf einem Segment. Daher existieren mehrere Werte für K pro Segment.

Aufgrund der variablen Segmentgröße kann kein fester Grenzwert T unabhängig von der Segmentgröße festgelegt werden. Daher wird der Grenzwert T in Abhängigkeit der durchschnittlichen Länge des Warping Pfades \bar{K} pro Segment als $T = \bar{K} \cdot t^2$ definiert,

wobei t die durchschnittlich erlaubte Abweichung in km/h zweier Geschwindigkeitsverläufe pro Messpunkt angibt. In Abbildung 4.11 ist die Anzahl der resultierenden Cluster über der gesamten Strecke in Abhängigkeit von t dargestellt.




Abbildung 4.11: Wahrscheinlichkeit für die Anzahl der resultierenden Cluster in Abhängigkeit des Grenzwertes t für den Clusteralgorithmus bei einer variablen Segmentgröße von $x_{min}=200$ m und $x_{max}=300$ m

Auf der x-Achse ist der Parameter t für das Intervall $I = [1, 15]$ aufgetragen. Auf der y-Achse ist die Anzahl der Cluster prozentual zur Strecke dargestellt. Für $t = 1$ bedeutet dies z. B., dass maximal $n = 9$ Cluster entstehen und dies auf ca. 15 % der Strecke. Im Gegensatz dazu ist der Anteil der Streckenelemente mit weniger als fünf Clustern kleiner als 10 %. Für $t = 15$ ergibt sich ein vollkommen anderes Bild: Es existieren maximal zwei Cluster, wobei in über 90 % der Fälle nur ein Cluster entstanden ist. Es besteht also ein sehr großer Unterschied zwischen $t = 1$ und $t = 15$. Das Ziel war es nun, den Bereich zu identifizieren, bei dem die Änderungen zwischen aufeinanderfolgenden t möglichst gering ist. In Abbildung 4.11 ist zu erkennen, dass sich die Anzahl der Cluster in dem Bereich zwischen $t = 5$ und $t = 9$ nur wenig ändert, weswegen für das hier gewählte Szenario der Mittelwert $t = 7$ gewählt wurde. Daraus folgt, dass $T = \bar{K} \cdot 7^2$ ist.

4.3.2.3 Berechnung charakteristischer Geschwindigkeitsverläufe

Um charakteristische Geschwindigkeitsverläufe über der Messstrecke zu berechnen, muss zunächst die Ähnlichkeit der Geschwindigkeitsverläufe in jedem Segment berechnet werden. Da die Ähnlichkeitsberechnung mittels DTW bei nur wenigen Elementen pro Geschwindigkeitsverlauf und Segment ungenau wird, wurde für jedes Profil an jedem Meter des Segments die Geschwindigkeit mittels linearer Interpolation berechnet und anschließend das Clusterverfahren mit den Parametern aus Abschnitt 4.3.2.2 angewendet. Abbildung 4.12 zeigt repräsentativ die Geschwindigkeitsverläufe des Teilstücks von 2000 m bis 4300 m der Messstrecke. Die roten vertikalen Linien markieren dabei die berechneten Segmentgrenzen mit den Parametern aus Tabelle 4.4.




Abbildung 4.12: Geschwindigkeitsverläufe für das Teilstück 2000 m bis 4300 m der Messstrecke und Segmentgrenzen

In der linken Hälfte der Grafik sind die Geschwindigkeitsverläufe in ihrer Form sehr ähnlich und unterscheiden sich im Wesentlichen nur bei ca. 2400 m und ca. 3100 m. Ab einer Distanz von 3500 m nimmt die Varianz zwischen den Geschwindigkeiten zu. Die dazu resultierenden Cluster für die einzelnen Segmente sind in Abbildung 4.13 dargestellt.

Zwischen 2000 m und 3500 m sind die entstandenen Cluster (jeweils ein oder zwei Cluster) deutlich zu erkennen. Ab 3500 m nimmt die Unähnlichkeit der Fahrprofile und somit auch die Anzahl der Cluster zu. In den folgenden Segmenten entstehen bis zu drei Cluster. Abschließend ist festzuhalten, dass mit Hilfe von DTW als Abstandsmaß und einem Clusterverfahren die Ähnlichkeit von Fahrprofilen auf Streckenabschnitten zu beurteilen ist. Bei großer Varianz in der Geschwindigkeit der Fahrprofile entstehen mehr Cluster




Abbildung 4.13: Cluster für das Teilstück 2000 m bis 4300 m (blaue Linien) der Messstrecke und Segmentgrenzen

und somit entsteht auch eine geringere Wahrscheinlichkeit das richtige Cluster auszuwählen.

4.3.2.4 Prognose des zukünftigen Geschwindigkeitsverlaufs

Der zukünftige Geschwindigkeitsverlauf ist eine Folge von repräsentativen Geschwindigkeitsverläufen der wahrscheinlichsten Cluster auf den vorausliegenden Segmenten in Abhängigkeit des zurückliegenden Geschwindigkeitsverlaufs. Dabei stellt sich die Frage, welchen Einfluss die Anzahl a der zurückliegenden Segmente, die mit in die Berechnung einbezogen werden, auf das FVP hat. Für $a = 1$ wird das FVP lediglich auf Basis des Geschwindigkeitsverlaufs im aktuellen Segment berechnet. Entsprechend wird die Prognose für $a = 5$ auf Basis des aktuellen und der vier zurückliegenden Segmente berechnet. Anhand der Messstrecke wurden die resultierenden FVP für verschiedene Werte von a untersucht.

In Abbildung 4.14 ist das resultierende FVP für unterschiedliche Werte für a dargestellt, wobei zu erkennen ist, dass a auf der gewählten Messstrecke nur einen sehr geringen Einfluss auf das FVP hat. Das FVP ist für $a = 1$, $a = 2$ und $a = 3$ komplett identisch. Die Verläufe für $a = 4$ und $a = 5$ sind auch größtenteils deckungsgleich und unterscheiden sich jeweils nur auf einem kurzen Streckenabschnitt von den anderen Verläufen. Die weiteren Untersuchungen zur Bestimmung des Kraftstoffesparpotenzials werden in dieser




Abbildung 4.14: FVP in Abhängigkeit der Fahrhistorie unterschiedlicher Länge. Der Parameter a bezeichnet die Anzahl der zurückliegenden Segmente.

Arbeit für $a = 5$ durchgeführt. In zukünftigen Arbeiten muss der Einfluss von a für weitere Strecken untersucht werden.

Der Wahrscheinlichkeitsgraph für die Messstrecke mit $a = 5$ auf der Teilstrecke von 2700 m bis 4300 m ist in Abbildung 4.15 als Beispiel dargestellt. Die Übergangswahrscheinlichkeiten sind neben den Kanten dargestellt und die hervorgehobenen Kanten markieren den wahrscheinlichsten Geschwindigkeitsverlauf, welches das FVP darstellt. In dieser Grafik bezeichnet $c(s_i, j)$ das j -te Cluster auf dem Segment i und $w(c(s_i, j), c(s_i + 1, k))$ die Wahrscheinlichkeit für einen Übergang vom Cluster $c(s_i, j)$ nach $c(s_i + 1, k)$.

4.3.2.5 Potenzial zur Kraftstoffeinsparung

Das Potenzial zur Kraftstoffeinsparung wird auf Basis des FVP für die gesamte Messstrecke berechnet. Im ersten Schritt werden für das FVP die drei Fahrverläufe (Eco, Normal und Sport) berechnet. Hierbei wird der sportliche Verlauf als Referenz gewählt, da dieser die meiste Dynamik aufweist und dadurch dem vorgegeben Geschwindigkeitsprofil am nächsten kommt. Die resultierenden Geschwindigkeitsverläufe sind in Abbildung 4.16 dargestellt. Der wesentliche Unterschied zwischen den Profilen ist das frühere Verzögern und das leichtere Beschleunigen bei den Fahrverläufen im Vergleich zum FVP.

Der relative Kraftstoffverbrauch und die relative Fahrtzeit der Fahrverläufe werden in Abbildung 4.17 verglichen. Also ist hier die Referenz mit 100 % Zeitbedarf und 100 %




Abbildung 4.15: Segmentübergreifender Wahrscheinlichkeitsgraph für die Streckendistanz 2700 m bis 4300 m. Hervorgehobene Kanten markieren den wahrscheinlichsten Geschwindigkeitsverlauf.

Kraftstoffverbrauch das Sport-Profil. Dabei ist zu erkennen, dass bei einer längeren Fahrtzeit von ca. 7 % bereits eine Einsparung von ca. 7 % erreicht werden kann (Normal-Fahrprofil). Mit steigender Fahrtzeit sinkt für das Eco-Fahrprofil der Kraftstoffverbrauch um bis zu 11 % bei einer um 17 % gesteigerten Fahrtzeit.

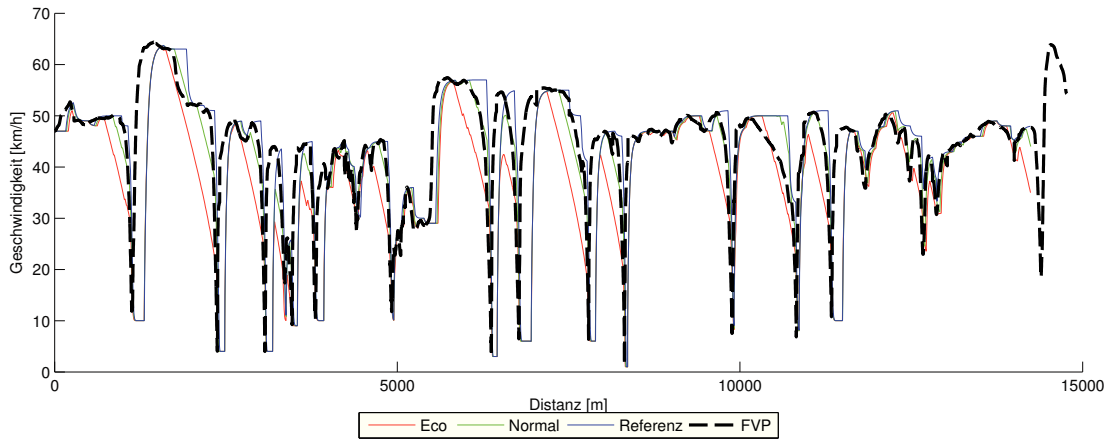


Abbildung 4.16: FVP und optimierte Fahrverläufe (RVPs) für die Messstrecke




Abbildung 4.17: Kraftstoffverbrauch in Abhängigkeit der Fahrtzeit der optimierten Geschwindigkeitsverläufe (RVPs)

4.4 Zusammenfassung und Ausblick

In diesem Abschnitt wurde zunächst ein System zur Berechnung und Bewertung von charakteristischen Geschwindigkeitsverläufen aus historischen Fahrprofilen entwickelt. Anschließend wurde ein Verfahren beschrieben, mit dem der wahrscheinlichste Geschwindigkeitsverlauf (das FVP) auf der vorausliegenden Strecke aus diesen Informationen berechnet werden kann. Aus dem FVP wurde im nächsten Schritt ein verbrauchsreduzierter Geschwindigkeitsverlauf abgeleitet, welcher als Input für zukünftige Fahrerinformationssysteme oder automatisierte Fahrfunktionen genutzt werden kann.

Zur Berechnung der charakteristischen Geschwindigkeitsverläufe wurde der DTW Algorithmus zur Bestimmung der Ähnlichkeit von Geschwindigkeitsverläufen als Abstandsmaß für ein hierarchisches Clusterverfahren vorgestellt. Das Ziel war es, ein Distanzmaß zu finden, das auch zueinander verschobene Geschwindigkeitsverläufe, z. B. aus unterschiedlichen Haltepositionen an Stopp-Schildern resultierend, als ähnlich identifiziert. DTW erreicht dies durch die Berechnung des sogenannten *Warping Pfades*. Weiterhin wurde ein Algorithmus zur Segmentierung der Gesamtstrecke entwickelt, mit dem Ziel, pro Streckensegment maximal ein Verkehrsereignis zu erhalten. Der Segmentierungsalgorithmus wurde anhand von realen Messdaten evaluiert und eine Parameterstudie durchgeführt. Zur Verwendung der charakteristischen Geschwindigkeitsverläufe wurde aufgezeigt, wie pro Segment für jeden charakteristischen Geschwindigkeitsverlauf ein repräsentativer Geschwindigkeitsverlauf berechnet werden kann.

Für die Bewertung der Geschwindigkeitsverläufe hinsichtlich ihrer Wahrscheinlichkeit wurde ein Verfahren vorgestellt, welches in Abhängigkeit der Position des Fahrzeugs und des zurückliegenden Geschwindigkeitsverlaufs die charakteristischen Geschwindigkeitsverläufe der vorausliegenden Segmente bewertet. Mittels dieser Bewertungen wurde daraufhin das FVP als eine Folge von repräsentativen Geschwindigkeitsverläufen der vorausliegenden Segmente berechnet. Für die Gesamtstrecke wurden im letzten Schritt zwei verschiedene RVP mit unterschiedlichem Zeitbedarf für die Strecke berechnet. Es wurde gezeigt, dass mit nur 7% mehr Zeitbedarf der Verbrauch auf dieser Strecke um ca. 7% reduziert werden kann. Mit 17% mehr Zeitbedarf ist sogar eine Reduzierung des Kraftstoffverbrauchs um ca. 11% zu erreichen.

Weiterhin ermöglicht der Algorithmus die Identifikation von Situationen im Straßenverkehr, bei welchen mit einer speziellen ursachenorientierten Analyse das FVP besser prognostiziert werden kann. Insbesondere die Identifikation der Positionen von Lichtsignalanlagen kann so durchgeführt werden.

Während der Arbeit an diesem Verfahren entstanden diverse weitere Fragestellungen, die in zukünftigen Arbeiten betrachtet werden sollten. Zum einen ist eine Erweiterung der Datenbasis mit Fahrprofilen unterschiedlicher Strecken erforderlich (z. B. auf Autobahnen), um die Ähnlichkeitsbestimmung der Fahrprofile mittels DTW und die Wahl der Segmentgröße weiter zu untersuchen. Im Anschluss daran ist in Fahrversuchen die Korrektheit der Wahrscheinlichkeiten der charakteristischen Geschwindigkeitsverläufe zu analysieren. Ein Human Machine Interface (HMI) zur Anzeige des FVP und des RVP inklusive Hinweise auf Fahrmanöver ist ebenfalls zu entwickeln und die Akzeptanz in Fahrerstudien zu bewerten. Auch wenn auf der Messstrecke die Anzahl der zurückliegenden Segmente bei der Berechnung des FVP keinen großen Einfluss auf das Ergebnis hatte, gilt es diesen Effekt auf weiteren Strecken zu untersuchen. In diesem Schritt sollten ebenfalls die hier bestimmten Parameter auf den unterschiedlichen Strecken evaluiert werden. Dabei kann eine digitale Karte eventuell die Grundlage für die zu wählenden Parameter sein.

Eine andere interessante Aufgabe ist es, den Einfluss von Fahrzeugen, welche bereits dieses System nutzen, auf die Datenbasis zu untersuchen. Dabei ist festzustellen, ob neue charakteristische Geschwindigkeitsverläufe entstehen und welchen Einfluss dies auf die Wahrscheinlichkeiten der charakteristischen Geschwindigkeitsverläufe hat. Eine weitere Idee ist die Verwendung von Fahrzeug-zu-Fahrzeug Kommunikation zur dynamischen Anpassung der Wahrscheinlichkeiten für die einzelnen charakteristischen Geschwindigkeitsverläufe während der Berechnung des FVP. Beispielsweise kann ein langsam vorausfahrendes Fahrzeug seine Geschwindigkeit kommunizieren, wodurch die Wahrscheinlichkeit für einen langsamen charakteristischen Geschwindigkeitsverlauf erhöht wird.

Kapitel 5

Lichtsignalanlagensteuerung: Grundlagen, Szenarien und Simulation

In den folgenden Kapiteln der Arbeit werden ursachenorientierte Algorithmen zur Berechnung des zukünftigen Geschwindigkeitsverlaufs an der nächsten Lichtsignalanlage (LSA) vorgestellt. Grundlage für diese Algorithmen ist die Kenntnis von LSA-Steuerungsalgorithmen. Daher werden in diesem Kapitel zunächst die Grundlagen der Lichtsignalanlagensteuerung mit Fokus auf die unterschiedlichen Steuerungsalgorithmen beschrieben (siehe Abschnitt 5.1). Die hohe Komplexität und zeitliche Variabilität einiger Steuerungsalgorithmen hat zur Folge, dass die ursachenorientierte Analyse nicht für alle Algorithmen möglich ist. Daher werden in Abschnitt 5.2 die Steuerungsalgorithmen und daraus abgeleitete Simulationsszenarien beschrieben, welche durch die in dieser Arbeit entwickelten Algorithmen adressiert werden. In Abschnitt 5.3 wird anschließend die Simulationsumgebung, die Implementierung der Steuerungsalgorithmen und die Schnittstelle zwischen Simulation und Auswertung beschrieben. Abschließend werden in Abschnitt 5.4 in der Literatur existierende Verfahren zur Reduzierung des Kraftstoffverbrauchs bei der Zufahrt auf eine durch eine LSA gesteuerte Kreuzung vorgestellt.

5.1 Allgemeine Einleitung zur Lichtsignalanlagensteuerung

LSA werden zur Steuerung des Verkehrs installiert und erhöhen die Verkehrssicherheit sowie die Qualität des Verkehrsflusses. Sie werden zur Verkehrsabwicklung an Knotenpunkten und Streckenabschnitten eingesetzt. Dort ermöglichen sie sicheres Überqueren der Straße für Fußgänger / Radfahrer, das Zusammenspiel von Öffentlichem Nahverkehr (ÖPNV) mit Kraftfahrzeugen und das effiziente Management von Verkehrsströmen. Der

Entwurf einer Lichtsignalanlagensteuerung muss zur Erreichung dieser Funktionalitäten sorgfältig und an die jeweilige Situation angepasst durchgeführt werden. Ein möglichst genaues Wissen über die örtlichen Begebenheiten und insbesondere die Verkehrsbelastung an dem Knotenpunkt ist dabei erforderlich. In Deutschland sind die „Richtlinien für Lichtsignalanlagen (RiLSA)“ [fSuV10] das Leitwerk zum Entwurf von LSA, aus welchem die Definitionen der Begriffe der Lichtsignalanlagensteuerung (Abschnitt 5.1.1) und auch die Steuerungsverfahren (Abschnitt 5.1.2) stammen. Das Leitwerk in den USA ist das „Traffic Control Systems Handbook“ [GToO⁺05]. Die aktuelle Forschung zur Lichtsignalanlagensteuerung beschäftigt sich im Wesentlichen mit Algorithmen zur Steigerung des Verkehrsflusses und der Reduktion des Kraftstoffverbrauches und der Emissionen. Aktueller Forschungsschwerpunkt sind modellbasierte Steuerungsverfahren, die jedoch aufgrund ihrer geringen Verbreitung (weniger als 1 % aller LSA in Deutschland) in dieser Arbeit nicht betrachtet werden.

5.1.1 Begriffe der Lichtsignalanlagensteuerung

In diesem Abschnitt werden die wesentlichen Begriffe der Lichtsignalanlagensteuerung erklärt, um bei der Beschreibung der Algorithmen dieser Arbeit auf diese zurückgreifen zu können.

Der Begriff des *Signalprogramms* beschreibt dabei den kompletten Ablauf der Signalsteuerung an einem Knotenpunkt im Straßennetzwerk. Eine *Signalgruppe* umfasst mehrere Signalgeber (Einheit zur Anzeige des Status an einem Knotenpunkt), die zu jeder Zeit das gleiche Signalbild (rot, grün oder gelb) zeigen. Eine Signalgruppe besteht z. B. aus Signalgebern gegenüberliegender Fahrtrichtungen. Die Zeit, in der sich der Zustand des Signalbildes nicht ändert, wird als *Phase* bezeichnet und ist Teil des Phasenplans der Signalsteuerung. Zur Phaseinteilung ist in [fSuV10, S. 13] zu finden:

„Bei der Phaseinteilung sind verträgliche, nichtverträgliche und bedingt verträgliche Verkehrsströme zu unterscheiden. Verträgliche Verkehrsströme haben keine gemeinsamen Konfliktflächen und können in einer Phase zusammengefasst werden. Nichtverträgliche Verkehrsströme haben eine gemeinsame Konfliktfläche und müssen getrennt freigegeben werden. Abbiegeströme, die gemeinsame Konfliktflächen mit Fahrzeugen des Gegenverkehrs oder mit parallelen Fußgänger- oder Radfahrerströmen haben, können als bedingt verträgliche Verkehrsströme mit diesen unter Beachtung der Vorrangregeln nach StVO gemeinsam freigegeben werden.“

Im Folgenden werden die mit der Phaseneinteilung einhergehenden Begriffe der Phasenanzahl, Phasenfolge und Phasenübergang erläutert.

Phasenanzahl: Die Phasenanzahl wird wesentlich durch die Anzahl der nicht verträglichen Verkehrsströme bestimmt. Soll eine technische Absicherung bedingt verträglicher Verkehrsströme stattfinden, müssen zusätzliche Phasen eingeführt werden. Bei einer Kreuzung mit vier Armen existieren mindestens zwei Phasen zur Absicherung der nicht verträglichen Verkehrsströme. Sollen auch nur bedingt verträgliche Verkehrsströme abgesichert werden, dann werden mindestens vier Phasen benötigt.

Phasenfolge: Die Phasenfolge bestimmt die zeitliche Abfolge der Phasen. Eine optimale Phasenabfolge minimiert die benötigten Zwischenzeiten zum Räumen des Knotenpunktes. Zur Erhöhung des Verkehrsflusses ist es möglich, einzelne Phasen mehrfach innerhalb einer Phasenfolge zu aktivieren. Eine Koordinierung von Signalprogrammen an aufeinanderfolgenden Knotenpunkten hat einen wesentlichen Einfluss auf die zeitliche Anordnung und Länge der Phasen.

Phasenübergang: Der Phasenübergang ist die Zeit vom Ende der Freigabezeit einer Phase bis zum Beginn der Freigabezeit der darauf folgenden Phase. Die Übergangszeiten und erforderlichen Zwischenzeiten sind in [fSuV10, S. 21ff.] im Detail beschrieben.

Die Zeit resultierend aus der Summe der Freigabezeiten aller maßgebenden Phasen und der erforderlichen Zwischenzeiten wird als *Umlaufzeit* bezeichnet. Die Umlaufzeit kann für jeden Knotenpunkt individuell bestimmt werden, muss aber, falls eine Koordinierung von benachbarten Knotenpunkten im Verkehrsnetz angestrebt wird, mit diesen abgestimmt werden. Dies hat zur Folge, dass die Umlaufzeiten von benachbarten Knotenpunkten in der Regel gleich sind, wenn eine „grüne Welle“ erreicht werden soll. Abhängig von dem gewählten Signalprogramm kann die Umlaufzeit statisch oder variabel über der Zeit sein.

5.1.2 Steuerungsverfahren für Lichtsignalanlagen

In den Richtlinien für LSA werden die unterschiedlichen Steuerungsverfahren und Anwendungsgebiete beschrieben. Die Steuerungsverfahren lassen sich nach Art der Veränderbarkeit der Parameter des Signalprogramms gruppieren. Zunächst werden die makroskopischen und mikroskopischen Verfahren zur Steuerung unterschieden. Verfahren auf

makroskopischer Steuerungsebene passen das Signalprogramm der LSA auf Basis makroskopischer Parameter an, wozu z. B. die Verkehrsdichte oder Tageszeit gehören. Auf dieser Steuerungsebene wird auf langfristige Verkehrseinflüsse reagiert. Im Gegensatz dazu gibt es die mikroskopische Steuerungsebene, auf welcher auf Verkehrseinflüsse an Einzelknotenpunkten reagiert wird. Solche Einflüsse können z. B. ein verlängerter Rückstau an einer Fahrtrichtung oder eine Phasenforderung von Öffentlichem Nahverkehr sein. Die makroskopische Steuerungsebene definiert somit in der Regel den Steuerungsrahmen, welcher durch die mikroskopische Steuerungsebene an die lokalen Verkehrsverhältnisse und Anforderungen angepasst werden kann. In Abbildung 5.1 werden die Steuerungsebenen, die darunter fallenden Steuerungsverfahren und die verkehrsabhängig veränderbaren Elemente der Signalprogramme dargestellt. Die makroskopische Steuerungsebene wird in Signalprogrammauswahl (zeitplanabhängig (A1) und verkehrsabhängig (A2)) und Bildung von Rahmensignalprogrammen (verkehrsabhängig (A3)) unterteilt. Diese drei Steuerungsverfahren werden in Kombination mit der mikroskopischen Steuerungsebene verwendet. Im Folgenden werden die makroskopischen Verfahren beschrieben:

Zeitplanabhängige Auswahl der Signalprogramme: Der zeitplanabhängigen Auswahl der Signalprogramme wird eine Beobachtung der tageszeitabhängigen Verkehrsdichte vorausgesetzt. Diese wird zum Anlass genommen, über den Tag verteilt unterschiedliche Freigabezeiten am Knotenpunkt in einzelnen Signalprogrammen (offline) festzulegen. Diese Programme werden dann in Abhängigkeit des Kalendertages und der Uhrzeit geschaltet.

Verkehrsabhängige Auswahl der Signalprogramme: Bei der verkehrsabhängigen Auswahl der Signalprogramme werden wiederum offline berechnete Signalprogramme in Abhängigkeit der aktuellen Verkehrsdichte ausgewählt. Die Verkehrsdichte wird dabei in der Regel durch Detektoren in den Knotenpunktzufahrten ermittelt. Dabei werden die Anzahl und die Abstände der Fahrzeuge gemessen. Anhand von Schwellwerten der Verkehrsdichte wird dann das entsprechende Signalprogramm ausgewählt.

Verkehrsabhängige Bildung der Rahmensignalprogramme: Bei der verkehrsabhängigen Bildung von Rahmensignalprogrammen wird nicht auf offline berechnete Signalprogramme zurückgegriffen und diese ausgewählt, sondern aus aktuellen Messwerten des Verkehrs ein Signalprogramm gebildet. Dieses Programm bildet dann den Rahmen für eine mikroskopische Anpassung, in dem z. B. die minimale / maximale Freigabezeit oder Phasenfolge vorgegeben ist.

Steuerungsverfahren	Oberbegriff	Hauptmerkmal der Veränderbarkeit der Signalprogramme	Ordnungszahl	Aktivierung				verkehrsabhängig veränderbare Elemente der Signalprogramme					
				zeitplan- abhängig	verkehrs- abhängig	Umlauf- zeit	Phasen- folge	Phasen- anzahl	Freigabe- zeiten	Versatz- zeit			
A: Makroskopische Steuerebene	Signalprogrammwahl	zeitplanabhängige Auswahl der Signalprogramme	A1		x								
		verkehrsabhängige Auswahl der Signalprogramme	A2		x								
		verkehrsabhängige Bildung der Rahmensignalprogramme	A3		x								
B: Mikroskopische Steuerebene	Festzeitsignalprogramm	Freigabezeit Anpassung	B1										
		Phasentausch	B2									x	
	Signalprogramm- anpassung	Phasenforderung	B3						x				
		Versatzzeit Anpassung	B4							x			
		freie Veränderbarkeit	B5										x
	Signalprogramm- bildung	freie Veränderbarkeit	B6					x		x			x

Abbildung 5.1: Algorithmen zur Steuerung von Lichtsignalanlagen nach RiLSA [fSuV10]

Die mikroskopische Steuerungsebene erlaubt kurzfristige Reaktionen auf Veränderungen und Anforderungen der Verkehrsteilnehmer an Einzelknotenpunkten. Dabei wird zwischen den Verfahren Festzeitsignalprogramm, Signalprogrammanpassung und Signalprogrammbildung unterschieden. Die Festzeitsignalprogramme (B1) und Signalprogrammbildung (B6) beschreiben zwei extreme Ausprägungen, bei denen zum einen alle Elemente der Signalprogramme unveränderbar (B1) und zum anderen vollständig veränderbar (B6) sind. Festzeitsignalprogramme werden insbesondere dann eingesetzt, wenn davon auszugehen ist, dass der Verkehrszustand über längere Zeit hinaus unverändert bleibt. Die Signalprogrammbildung wird im gegenteiligen Fall eingesetzt. Die Verfahren der Signalprogrammanpassung (B2-B5) werden im Folgenden beschrieben:

Freigabezeitanpassung: Bei der Freigabezeitanpassung kann frühestens nach Ablauf einer minimalen Freigabezeit bei Bedarf zugunsten einer anderen Fahrtrichtung geschaltet werden. Der Bedarf wird in der Regel anhand von aktuellen Messungen der Verkehrsdichte, Belegungsgraden oder Staulängen durchgeführt.

Phasentausch: Beim Phasentausch wird die vorgegebene Phasenfolge unter Beibehaltung der Anzahl der Phasen verändert. Dieses Verfahren wird in der Regel zur Beschleunigung des öffentlichen Personennahverkehrs eingesetzt.

Phasenanforderung: Die Phasenanforderung wird bei einer bedarfsgerechten Steuerung von selten auftretenden Verkehrsströmen eingesetzt. Dabei wird eine zusätzliche Phase dem Phasenplan hinzugefügt, um z. B. Fußgängern oder abbiegenden Verkehrsströmen nur im Bedarfsfall eine Grünzeit einzuräumen. Dieses Verfahren wird ebenfalls zur Beschleunigung von ÖPNV-Fahrzeugen eingesetzt, falls zum Ankunftszeitpunkt keine Freigabe durch eine Freigabezeitanpassung realisiert werden kann. Dazu muss das ÖPNV-Fahrzeug den Bedarf möglichst frühzeitig (500 m) vor dem Knotenpunkt melden.

Versatzzeitanpassung: Die Versatzzeitanpassung wird insbesondere zur Abstimmung der Freigabezeiten von benachbarten Knotenpunkten verwendet. Dabei sind die Anfangszeitpunkte aller Freigabezeiten in einem bestimmten Rahmen variierbar und es kann so auf wechselnde Verkehrsbelastungen reagiert werden.

Zur Verkehrssteuerung wird ein weiteres planerisches Verfahren eingesetzt: Die Koordination der Freigabezeiten von benachbarten LSA oder kompletten Straßenzügen resultieren in einer „grünen Welle“. Das Ziel dieser Koordination ist, stets die Reisezeiten und die Anzahl der Halte der einzelnen Verkehrsteilnehmer zu verringern und folgerichtig auch die Emissionen zu senken. Eine Koordination wird in der Regel zur Bündelung

von Verkehrsströmen auf Hauptverkehrsstraßen angewendet. Dazu werden die Freigabezeiten der LSA an aufeinander folgenden Knotenpunkten versetzt zueinander geschaltet. Mittels Freigabe- und Versatzzeitanpassung kann eine Koordinierung verkehrabhängig gesteuert werden. Dabei ist zu beachten, dass die Umlaufzeit der benachbarten LSA gleich zu sein hat. Der Entwurf von entsprechenden Schaltungen wird im Detail in [fSuV10, S. 43ff.] beschrieben.

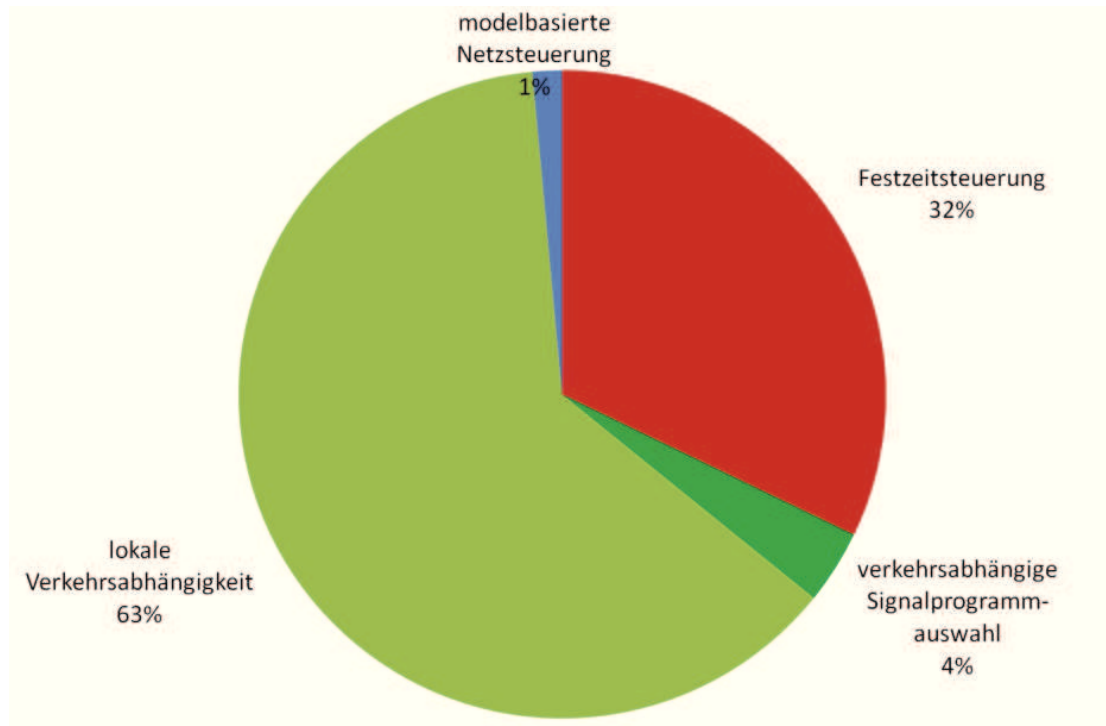


Abbildung 5.2: Lichtsignalanlagen in Deutschland - Eine Befragung von 21 Städten (Quelle: [Fri09])

Einen Überblick über die in Deutschland eingesetzten Verfahren zur Lichtsignalanlagensteuerung gibt Abbildung 5.2. In Deutschland existieren ca. 60.000 LSA, wobei nach einer Befragung von 21 Städten davon ca. 32% durch eine Festzeitsteuerung kontrolliert werden. Insgesamt 63% werden in Abhängigkeit des lokalen Verkehrsaufkommens gesteuert, worunter 33% auf die Priorisierung des Öffentlichen Nahverkehrs entfallen. Modellbasierte Steuerungen, wie sie in aktuellen Forschungsprojekten meistens untersucht werden, sind nur an 1% aller LSA zu finden und werden daher auch nicht weiter in dieser Arbeit betrachtet.

Statistiken aus den USA [RIT] zeigen, dass ca. 29% aller Knotenpunkte mit Festzeitsteuerung arbeiten. 32% werden verkehrabhängig durch Detektoren auf der Neben-

verkehrsrichtung („Semi-actuated“) gesteuert und dementsprechend ca. 39 % („Fully-actuated“) mit Detektoren auf beiden Verkehrsrichtungen. Davon sind außerdem ca. 75 % mit benachbarten Knotenpunkten koordiniert.

5.2 Auswahl der Simulationsszenarien

In dieser Arbeit werden die beiden Algorithmen TLSE und TLCorA vorgestellt. Beide Algorithmen erlauben eine Identifikation von charakteristischen Geschwindigkeitsverläufen und ihrer Wahrscheinlichkeit bei der Zufahrt auf eine LSA für den Fall, dass die LSA durch ausgewählte Steuerungsverfahren kontrolliert wird. TLSE ist es möglich, die Freigabezeiten der Steuerung für den Fall zu bestimmen, dass die Umlaufzeit und Phasenfolge über einen gewissen Zeitraum statisch sind. Im Gegensatz dazu adressiert TLCorA auch LSA mit variabler Umlaufzeit, wobei jedoch die Umlaufzeit der vorausliegenden LSA mit der Umlaufzeit einer zurückliegenden LSA korreliert sein muss. Entsprechend der adressierten Anwendungsfälle von TLSE und TLCorA werden im Folgenden Verfahren zur Steuerung ausgewählt und die dazugehörigen Simulationsszenarien beschrieben.

TLSE adressiert Steuerungsverfahren mit konstanter Umlaufzeit über einen bestimmten Zeitraum und einer gleichbleibenden Phasenabfolge. Das entspricht also den Steuerungsverfahren, die auf mikroskopischer Steuerungsebene die Verfahren B1,B2, B5 einsetzen (siehe Abbildung 5.1). Dazu zählen ebenfalls die weit verbreiteten Verfahren der makroskopischen Steuerungsebene A1-A2 (tageszeitabhängige und verkehrsabhängige Auswahl der Signalprogramme) und insbesondere das auf mikroskopischer Steuerungsebene häufig eingesetzte Verfahren der Freigabezeitanpassung. Für den Fall, dass Phasentausch und Phasen Anforderung (B3-B4) eingesetzt werden, ist in der Regel die Umlaufzeit auch konstant, jedoch variiert die Phasenfolge. Solche Änderungen in der Phasenfolge würde TLSE als Messfehler betrachten und die Abfolge der „üblichen“ Phasen schätzen. Aufgrund der hohen Variabilität ist eine Prognose von Phasentausch und Phasen Anforderung sehr schwierig und wird nicht durch TLSE adressiert.

TLCorA versucht die Korrelation von LSA an benachbarten bzw. aufeinander folgenden Knotenpunkte zu erkennen. Voraussetzung für eine erfolgreiche Berechnung des wahrscheinlichsten Geschwindigkeitsprofils mittels TLCorA ist daher ein fester relativer Zeitpunkt für den Beginn der Freigabezeiten an zwei Knotenpunkten und damit die gleiche Umlaufzeit der LSA an diesen Knotenpunkten. Im Vergleich zu TLSE muss diese Umlaufzeit jedoch nicht konstant über einen bestimmten Zeitraum sein, sondern kann

von Zyklus zu Zyklus variieren. Ebenfalls vorausgesetzt wird, wie bei TLSE, eine feste Phasenanzahl und Phasenfolge. Zusätzlich zu den adressierten Steuerungsverfahren von TLSE werden durch TLCorA auch bestimmte Verfahren der Signalprogrammbildung (B6) der mikroskopischen Steuerungsebene adressiert.

Beim Entwurf von LSA-Steuerungen an Knotenpunkten hat die Anzahl von nicht verträglichen und bedingt verträglichen Strömen einen wesentlichen Einfluss auf die Phasenanzahl der Steuerung. In dieser Arbeit werden Steuerungen mit zwei und vier Phasen untersucht, welche aufgrund ihrer Häufigkeit im realen Straßenverkehr ausgewählt wurden. Die vorgestellten Algorithmen TLSE und TLCorA sind allerdings auch auf Steuerungen mit mehr als vier Phasen anwendbar, wenn die oben genannten Randbedingungen gegeben sind. In dieser Arbeit werden die in Tabelle 5.1 gezeigten Szenarien untersucht.

Szenario	Phasenanzahl	Steuerungsverfahren	Verkehrsdichte
1	Zwei Phasen	Festzeitsteuerung	konstant
2	Vier Phasen	Festzeitsteuerung	konstant
3	Zwei Phasen	tageszeitabhängig	tageszeitabhängig
4	Zwei Phasen	Freigabezeitanpassung	tageszeitabhängig
5	Zwei Phasen	Signalprogrammbildung	tageszeitabhängig

Tabelle 5.1: Simulationsszenarien

Szenario 1 ist eine Festzeitsteuerung mit zwei Phasen, bei welcher weder auf der makroskopischen noch auf der mikroskopischen Steuerebene Anpassungen der Steuerung vorgenommen werden. Der Verkehrsfluss wird als konstant über der Zeit angenommen und als Poisson-Verteilung modelliert. In Szenario 2 wird ebenfalls eine Festzeitsteuerung umgesetzt, jedoch mit vier Phasen an einem größeren Knotenpunkt. Der Verkehrsfluss ist wieder konstant.

Eine tageszeitabhängige Steuerung auf makroskopischer Ebene (A1) mit einer Festzeitsteuerung (B1) auf mikroskopischer Ebene wird in Szenario 3 umgesetzt. Vier verschiedene Signalprogramme werden den Tag über geschaltet. Beginnend mit einem Programm in der Nacht, ein Programm für den morgendlichen Berufsverkehr, ein Programm für den abendlichen Berufsverkehr und ein letztes für die Zwischenzeiten. Bei einem Wechsel von einem Signalprogramm in ein anderes werden alle veränderlichen Elemente der Steuerung (inkl. Umlaufzeit) verändert. Passend zu der tageszeitabhängigen Steuerung wird auch der Verkehr tageszeitabhängig modelliert.

In Szenario 4 wird eine Freigabezeitanpassung (B1) auf mikroskopischer Steuerebene ohne eine zusätzliche Steuerung auf makroskopischer Ebene realisiert. Der Verkehrsfluss

ist erneut tageszeitabhängig als Poisson-Verteilung modelliert, sodass die Freigabezeiten über den Tag stark variieren, um den Anforderungen des Verkehrs gerecht zu werden. Der Algorithmus der Freigabezeitenanpassung für dieses Szenario wird in Abbildung 5.3 dargestellt.

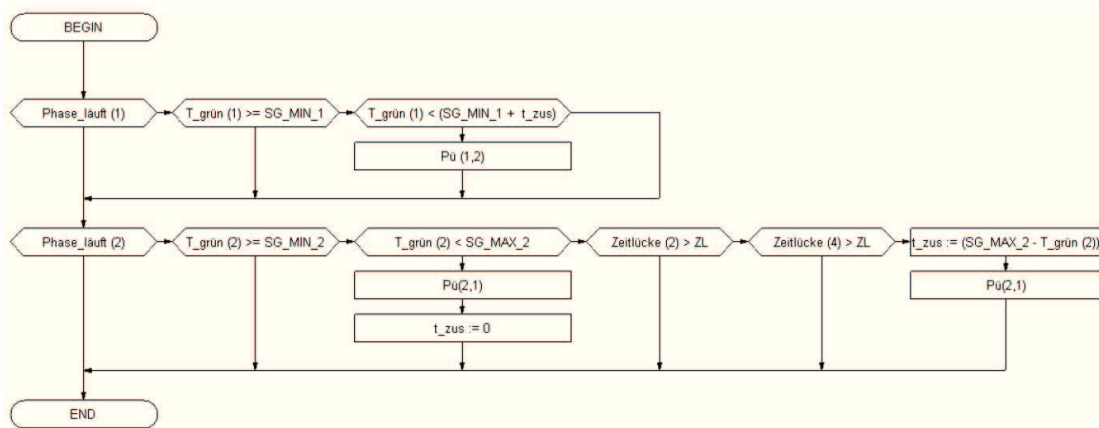


Abbildung 5.3: Ablauf der Freigabezeitenanpassung für Szenario 4 (Quelle: [Oer09])

Der Algorithmus beginnt für alle Szenarien mit Phase 1, in welcher die Freigabezeit für die Hauptverkehrsrichtung gesteuert wird. Die Steuerung schaltet solange grün, bis die Freigabezeit T_{gruen} die minimale Freigabezeit SG_{MIN} und die zusätzliche Zeit t_{zus} (die Restzeit aus Phase 2) erreicht hat. Anschließend wird der Phasenübergang $Pü(1,2)$ durchgeführt. In der Nebenverkehrsrichtung wird die Freigabezeit der Phase 2 aufgrund von Zeitlückenmessungen an den Detektoren (Induktionsschleifen in 30 m Distanz zur Haltelinie) der beiden Zufahrten früher beendet, falls die Zeitlücke zwischen zwei Fahrzeugen einen bestimmten Schwellwert ZL überschreitet. Die zusätzliche Zeit für Phase 1 wird anschließend aus der maximalen Freigabezeit SG_{MAX} und der freigegebenen Zeit in der aktuellen Phase $T_{gruen}(2)$ als $t_{zus} = SG_{MAX} - T_{gruen}(2)$ berechnet, anschließend wird ein Phasenübergang durchgeführt. Durch dieses Vorgehen wird der Hauptverkehrsrichtung stets die nicht benötigte Freigabezeit der Nebenverkehrsrichtung zugewiesen und dabei die Umlaufzeit an diesem Knotenpunkt nicht verändert. In der Implementierung wurde als Phasenübergang eine Gelbzeit von drei Sekunden angesetzt.

In Abbildung 5.4 wird der in dieser Arbeit implementierte Algorithmus zur Signalprogrammmanpassung (Szenario 5) dargestellt. Hierbei ist zusätzlich zur Nebenverkehrsrichtung auch noch die Hauptverkehrsrichtung mit Detektoren ausgestattet, wodurch auch in dieser Richtung die Zeitlückenmessung durchgeführt und frühzeitig wieder zur Nebenverkehrsrichtung umgeschaltet werden kann.

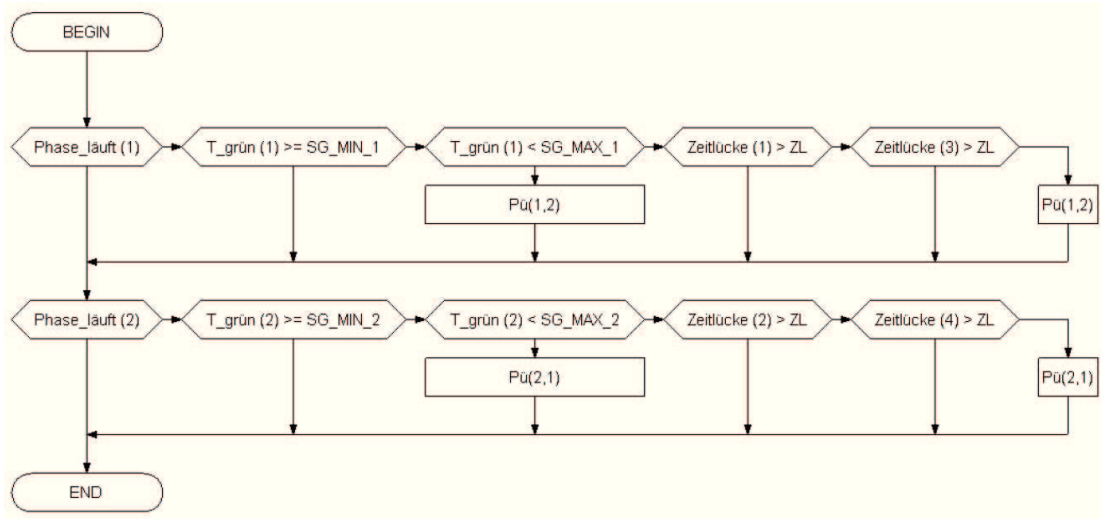


Abbildung 5.4: Ablauf der Signalprogrammierung (Szenario 5) (Quelle: [Oer09])

Die minimalen und maximalen Freigabezeiten der beiden Verkehrsrichtungen sind durch die Werte $SG_{MIN}(1)$, $SG_{MIN}(2)$ respektive $SG_{MAX}(1)$ und $SG_{MAX}(2)$ beschrieben. Im Gegensatz zur Freigabezeit Anpassung wird nun die Restzeit t_{zus} nicht mehr der Freigabezeit der Hauptverkehrsrichtung zugewiesen. Dadurch ist die Umlaufzeit bei der Signalprogrammierung nicht mehr konstant, sondern ändert sich in Abhängigkeit der Verkehrsdichte in jedem Zyklus. Durch diese Schaltung kann sehr schnell auf Veränderungen des Verkehrsflusses reagiert werden, eine Koordinierung ist jedoch nicht mehr möglich.

Insgesamt decken die fünf Szenarien ein weites Spektrum der in den Richtlinien für LSA beschriebenen makroskopischen und mikroskopischen Steuerungen und insbesondere den Großteil der heutzutage eingesetzten Steuerungen in der Realität ab. Es werden die unterschiedlichen Algorithmen an Knotenpunkten mit Zwei-Phasen-Steuerung evaluiert und zusätzlich für eine Festzeitsteuerung an einem Knotenpunkt mit Vier-Phasen-Steuerung nachgewiesen. Da in der Realität nicht bekannt ist, an welchem Knotenpunkt TLSE und/oder TLCoRA eingesetzt werden können, besteht die Anforderung, Fehlfunktionen im Falle einer Steuerung mit zu hoher Variabilität zu erkennen und so Fehlinformationen an die Fahrzeuge zu vermeiden. Um diese Detektion testen zu können, wurde Szenario 5 ausgewählt, da die Steuerung eine maximale Variabilität hat.

5.3 Beschreibung der Simulationsumgebung

Die im vorherigen Abschnitt beschriebenen Szenarien werden in dem Verkehrssimulator SUMO [KHRW02] umgesetzt. SUMO ist eine frei verfügbare mikroskopische Verkehrssimulation mit dem sogenannten *Traffic Control Interface* (TraCI [WPR⁺08]), welches unter anderem einen Zugriff auf die Fahrzeugbewegungen in jedem Simulationsschritt erlaubt, aber auch die Kontrolle von LSA zu jedem Zeitpunkt ermöglicht.

Das Straßennetzwerk für die Simulationen wurde einheitlich für alle Szenarien gewählt und basiert auf einem Beispiel aus der Anlage der Richtlinien für LSA [fSuV10]. Es besteht aus fünf aufeinander folgenden Knotenpunkten, welche die Hauptfahrtrichtung von West nach Ost bzw. von Ost nach West beschreiben. Abbildung 5.5 zeigt das Straßennetzwerk, die Fahrtrichtungen und die Abstände zwischen den Knotenpunkten.




Abbildung 5.5: Das Straßennetzwerk der Simulation bestehend aus fünf benachbarten Knotenpunkten

Zur Realisierung der Szenarien mit unterschiedlicher Phasenanzahl wurden zwei Layouts für die Knotenpunkte entworfen. Der Knotenpunkt in Abbildung 5.6(a) zeigt das Layout für eine Zwei-Phasen-Schaltung, wobei Fahrzeugen das Abbiegen an Knotenpunkten nicht erlaubt ist. Durch diese Beschränkung existieren nur zwei voll verträgliche Verkehrsströme, welche durch die Zwei-Phasen-Schaltung technisch abgesichert werden. Es existieren daher in den Simulationen zwei Hauptverkehrsströme von West nach Ost und umgekehrt. Die Nebenverkehrsrichtungen führen jeweils von Nord nach Süd und umgekehrt. Angelehnt an das Beispiel aus den RiLSA ist der Verkehrsfluss auf den Hauptrichtungen deutlich höher als auf den Nebenrichtungen. Dadurch sollte auch die Freigabezeit

der Strecke West-Ost bzw. Ost-West deutlich länger als auf der Nebenrichtung sein, um einen reibungslosen Verkehr zu realisieren.

In Abbildung 5.6(b) ist das Layout eines komplexeren Knotenpunktes dargestellt, welcher für das Szenario mit Vier-Phasen-Steuerung verwendet wird. Für dieses Szenario werden alle Knotenpunkte des oben gezeigten Straßennetzwerkes mit diesem Layout simuliert. Das Abbiegen der Fahrzeuge ist in allen Fahrtrichtungen erlaubt und technisch durch die Vier-Phasen-Steuerung vollständig abgesichert. In diesem Szenario wurden drei Bewegungsklassen für die Fahrzeuge definiert: Der ersten Klasse gehören Fahrzeuge an, die jeden Knotenpunkt geradeaus überqueren. Die zweite und die dritte Klasse beschreiben die Fahrzeuge, die bei jedem Knotenpunkt rechts bzw. links abbiegen. Am Ende des Straßennetzwerkes verlassen die Fahrzeuge die Simulation.

Das Eintreten der Fahrzeuge in die Simulation am Rande des Straßennetzwerkes (dadurch auch der Verkehrsfluss) ist in allen Szenarien als Poisson-Verteilung modelliert. Der Verkehrsfluss ist abhängig vom Szenario entweder statisch oder tageszeitabhängig. Die statischen Verkehrsflüsse sind wiederum den Beispielen der RiLSA entnommen. Die tageszeitabhängigen Verkehrsflüsse kommen aus realen Detektormessungen aus dem deutschen Förderprojekt ORINOKO [Reg10].


Die Parameter der SUMO-Simulation bezüglich der Fahrzeugcharakteristiken werden in Tabelle 5.2 dargestellt.

Parameter	Wert
Geschwindigkeitsbegrenzung	50 km/h
Maximale Fahrzeugbeschleunigung	2,6 m/s
Maximale Fahrzeugverzögerung	4,5 m/s
Sigma der Fahrzeugbewegung	0,5
Fahrzeu glänge	4,5 m
Position der Detektoren	30 m vor der Haltelinie

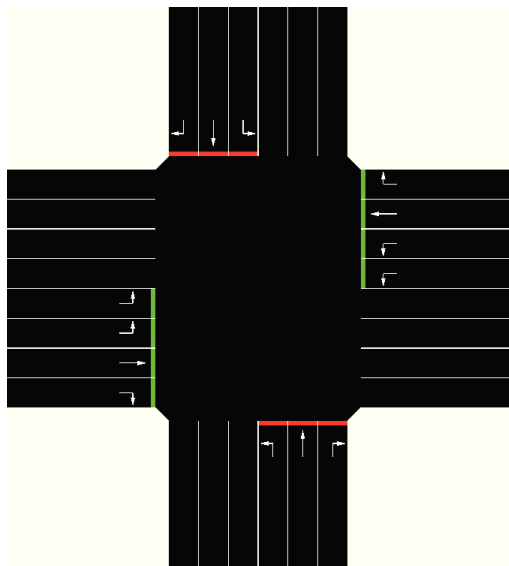
Tabelle 5.2: Konfigurationsparameter der SUMO-Simulation

Die Signalprogramme der Szenarien 1-3, die Festzeitsteuerungen und tageszeitabhängige Steuerung, sind über die Konfigurationsdateien der SUMO-Simulation gesteuert. Die anderen Szenarien, in denen die Steuerung mit Freigabezeitanpassung und Signalprogrammabbildung realisiert sind, werden mittels des *Traffic Control Interface (TraCI* [WPR⁺08]) umgesetzt. Dabei werden zu jedem Simulationsschritt die Messungen der Detektorschleifen von einer in dieser Arbeit entwickelten Steuerungssoftware analysiert und entsprechend der oben beschriebenen Algorithmen wird die Steuerung der LSA vorgenommen.

Da diese Arbeit das Ziel verfolgt, den Kraftstoffverbrauch bei der Zufahrt auf LSA für alle Fahrzeuge zu reduzieren, werden im nächsten Abschnitt zunächst noch andere Verfahren zur Reduzierung des Kraftstoffverbrauchs vorgestellt. Diese Verfahren treten in Konkurrenz zu den in dieser Arbeit entwickelten ursachenorientierten Algorithmen.



(a) Knotenpunkt mit Zwei-Phasen-Steuerung, wobei aus jeder Fahrtrichtung zwei Fahrstreifen kommen und der Knotenpunkt nur geradeaus überquert werden darf.



(b) Layout der Knotenpunkte mit Vier-Phasen-Steuerung. Vier zuführende Fahrstreifen von West nach Ost bzw. Ost nach West. Davon sind zwei Spuren für Linksabbieger, eine Spur für das geradeaus Überqueren und eine Spur zum Rechtsabbiegen. Für die Fahrtrichtungen von Nord und Süden kommend existiert eine Fahrspur für jede mögliche Fahrtrichtung.

Abbildung 5.6: Die Knotenpunkte in der Simulationsumgebung

5.4 Verfahren zur Reduzierung des Kraftstoffverbrauchs an Kreuzungen

In diesem Abschnitt wird der Stand der Technik in Bezug auf Systeme zur Reduzierung des Kraftstoffverbrauchs durch Information des Fahrers über die Geschwindigkeitseinflüsse auf dem vorausliegenden Streckenabschnitt diskutiert. Es werden Systeme beschrieben, die zum einen auf Fahrzeugsensorik und einer digitalen Karte aufbauen, zum anderen aber auch Systeme, welche Fahrzeug-zu-Fahrzeug oder Infrastruktur-zu-Fahrzeug Kommunikation verwenden.

Die Entwicklung von Assistenzsystemen zur Kraftstoffeinsparung ist schon länger im Fokus vieler Automobilhersteller und Forschungseinrichtungen weltweit. Zur Reduzierung des Kraftstoffverbrauchs an LSA wurden sogenannte Green Light Optimal Speed Advisory (GLOSA) Systeme entwickelt und an einigen Kreuzungen installiert. Diese Systeme informieren heranfahrende Fahrzeuge über die optimale Geschwindigkeit oder verbleibende Rotzeit, um die Kreuzung ohne Haltevorgang zu passieren.

Zur Information werden hierbei Wechselverkehrszeichen oder sogenannte Road Side Unit (RSU) verwendet, welche mit Dedicated Short Range Communication (DSRC) Modulen ausgestattet sind. Das Potenzial der Systeme basierend auf DSRC, welche den aktuellen und zukünftigen Status der LSA versenden, wurde in [BKM⁺09, WHWL08] analysiert. Simulationsergebnisse aus [WHWL08] zeigen ein Potenzial zur Kraftstoffreduzierung von ca. 20 % von ausgestatteten Fahrzeugen im Vergleich zu Fahrzeugen ohne DSRC Modul. Aufgrund der hohen Installations- und Instandhaltungskosten von GLOSA Systemen sind diese nicht weit verbreitet.

Mit der ursachenorientierten Analyse von Fahrprofilen an LSA stellen wir daher Systeme vor, welche nicht auf dem Aufbau von Infrastruktur an Kreuzungen basieren, sondern die Schaltzeitpunkte von LSA aus gesammelten Beobachtungen des LSA Status von Fahrzeugen über der Zeit erlernen. Ein ähnlicher Ansatz wird bereits in [KPM11] durch die Autoren vorgeschlagen. Dort wird diskutiert, Mobiltelefone mit einer Kamera unter die Windschutzscheibe zu montieren, um die Schaltzeitpunkte von LSA zu beobachten und anschließend durch Austausch von Beobachtungen mit anderen Fahrzeugen diese zu erlernen. Im Gegensatz zu der Verwendung von Mobiltelefonen mit Kameras basiert unser vorgeschlagenes System ausschließlich auf gesammelten Fahrprofilen.

Die zukünftige Geschwindigkeit bei Zufahrt auf eine LSA wird jedoch nicht ausschließlich durch den Status der LSA beeinflusst, sondern auch durch den Rückstau an der LSA

zum Zeitpunkt der Ankunft. Daher erfordert eine zuverlässige Prognose des zukünftigen Geschwindigkeitsprofils an Kreuzungen stets auch eine Schätzung der Rückstaulänge. Eine mögliche Lösung wird bereits in [Pri10] vorgestellt. Aus diesem Grund legen wir den Fokus bei der Entwicklung der Algorithmen in dieser Arbeit nicht auf diese Fragestellung.

Kapitel 6

TLSE: Ursachenorientierte Analyse zum Lernen der LSA-Schaltzeiten

Die für einen Fahrer maximal fahrbare Geschwindigkeit in einer spezifischen Situation wird durch verschiedene Parameter beeinflusst. Auf Landstraßen und Autobahnen haben Streckengeometrie, Verkehrszeichen und Verkehrsfluss wesentlichen Einfluss auf die Geschwindigkeit. Im Gegensatz dazu wird die Geschwindigkeit innerorts signifikant durch LSA beeinflusst. Diese haben ständiges Anhalten und Losfahren von Fahrzeugen mit der Konsequenz eines erhöhten Kraftstoffverbrauchs zur Folge.

Um auch bei der Zufahrt auf eine LSA die zu erwartende Geschwindigkeit zum Zeitpunkt der Ankunft des Fahrers berechnen zu können, wird in diesem Kapitel die ursachenorientierte Analyse zum Lernen der LSA-Schaltzeiten beschrieben. Der Traffic Light State Estimation (TLSE) Algorithmus erlernt die Phasenpläne der LSA-Steuerung (im Folgenden als LSA-Parameter bezeichnet) aus „Beobachtungen“ von Fahrzeugen auf einem Server. Eine solche Beobachtung besteht dabei (für ein Fahrzeug das an der Kreuzung angehalten hat) aus dem Zeitpunkt des Stoppens, des Losfahrens, der Distanz beim Stopp zur Haltelinie und dem Zeitpunkt der Überfahrt der Haltelinie. Das Wissen über die Positionen von Haltelinien an Kreuzungen werden dabei als gegeben vorausgesetzt. Basierend auf den LSA-Parametern wird der Status der LSA zu jedem beliebigen Zeitpunkt in der Zukunft und die zu erwartende Geschwindigkeit bei Ankunft an der LSA für alle Fahrzeuge berechnet.

Durch das Wissen über die Positionen der Haltelinien ist der wesentliche Einfluss auf den Geschwindigkeitsverlauf an dieser Position bekannt. TLSE extrahiert Beobachtungen aus historischen Fahrprofilen an diesen Positionen und schließt daraus auf die LSA-Parameter der Steuerung für den Fall, dass die Umlaufzeit über einen gewissen Zeitraum

statisch ist. Für den nicht-statischen Fall liefert TLSE lediglich eine ungenaue Schätzung für die LSA-Parameter mit einer Standardabweichung.

Das Vorgehen von TLSE ist folgendermaßen: Für jede einzelne Fahrtrichtung (Quelle-Ziel-Matrix der Kreuzungsarme) an der Kreuzung schätzt TLSE zunächst die Parameter der fahrtrichtungsspezifischen Phase. Ziel der LSA-Steuerung an einer Kreuzung ist die Koordinierung der verträglichen, nicht verträglichen und bedingt verträglichen Verkehrsflüsse aus den unterschiedlichen Fahrtrichtungen. Verträgliche Fahrtrichtungen haben im gleichen Zeitraum das Recht zu fahren (sind in einer Phase), andere sind nicht verträglich (sind in unterschiedlichen Phasen) und haben daher zu unterschiedlichen Zeiten das Recht zu fahren. Diese Abhängigkeit zwischen Fahrtrichtungen nutzt TLSE in einem zweiten Schritt aus, um die Schätzung der LSA-Parameter der einzelnen Fahrtrichtungen zu verbessern. Mit Kenntnis der LSA-Parameter kann der Status der LSA zum Zeitpunkt der Ankunft berechnet und dem Fahrer angezeigt oder ein kraftstoffesparendes Manöver durch ein weiteres Fahrerassistenzsystem berechnet werden.

Der in diesem Kapitel beschriebene Algorithmus ist in [KWSM12] veröffentlicht. Die Idee zu diesem Algorithmus ist vom Autor dieser Arbeit gemeinsam mit den Koautoren der Veröffentlichung entwickelt worden. Die Implementierung und Auswertung ist alleine durch den Autor dieser Arbeit durchgeführt worden.

In Abschnitt 6.1 wird zunächst die Schätzung der spezifischen LSA-Parameter für die einzelne Fahrtrichtungen an der Kreuzung beschrieben. Darauf folgend wird in Abschnitt 6.2 die Zusammenführung der LSA-Parameter der unterschiedlichen Fahrtrichtungen vorgestellt. Die Ergebnisse aus der Validierung von TLSE in der Simulationsumgebung (siehe Abschnitt 5.2) werden in Abschnitt 6.3 dargestellt. Abschließend werden in Abschnitt 6.4 die wesentlichen Beiträge zusammengefasst und weitere Fragestellungen identifiziert.

6.1 Schätzen der spezifischen LSA-Parameter einer Fahrtrichtung

In diesem Abschnitt wird das Schätzen der fahrtrichtungsspezifischen LSA-Parameter aus den „Beobachtungen“ (extrahiert aus den gesammelten Fahrprofilen) durch TLSE beschrieben. Die Phase einer Fahrtrichtung wird durch die folgenden Parameter modelliert: Länge des Zyklus l_z (auch: Umlaufzeit), Offset des Zyklus (dt) und Länge der

Grünzeit (lg). Dazu wird vorerst angenommen, dass jede Fahrtrichtung innerhalb eines Zyklus einmal grün und einmal rot hat.¹

Weiterhin gilt ohne Beschränkung der Allgemeinheit, dass für jede Fahrtrichtung der Zyklus mit einer Grünphase startet, welcher über den Offset (dt) zu einem absoluten Zeitpunkt (t_{ref}) in zeitliche Relation zu anderen Fahrtrichtungen gebracht wird². Die Gelbzeit wird durch TLSE nicht separat modelliert, sondern entsprechend der Grünzeit bzw. Rotzeit zugeordnet. Die Rotzeit ergibt sich daher aus der Differenz von Zykluszeit und Grünzeit. Abbildung 6.1 stellt die fahrtrichtungsabhängigen Parameter dar.

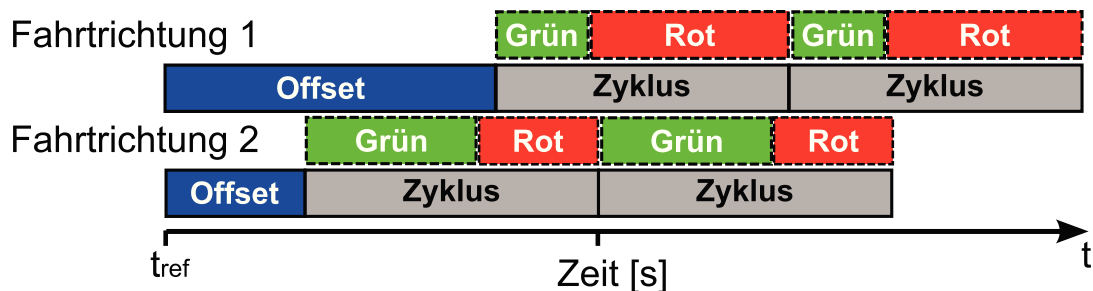


Abbildung 6.1: LSA-Parameter zweier Fahrtrichtungen: Länge des Zyklus (lz) in Sekunden, Länge der Grünzeit (lg) im Zyklus in Sekunden und Offset des Zyklusstarts (dt) zu einem absoluten Referenzzeitpunkt

TLSE schätzt die fahrtrichtungsabhängigen Parameter in den folgenden Schritten:

1. Extrahieren der „Beobachtungen“ über den Status der LSA aus gesammelten Fahrprofilen (siehe Abschnitt 6.1.1)
2. Schätzen der Länge des Zyklus (lz) und des Offsets (dt) durch Optimierung (siehe Abschnitt 6.1.2) auf Basis der Beobachtungen
3. Bestimmen der Länge der Grünzeit lg (siehe Abschnitt 6.1.3)

6.1.1 Extrahieren der Beobachtungen über den LSA-Zustand

Bei der Überfahrt einer durch eine LSA gesteuerten Kreuzung wird das Fahrprofil der Fahrzeuge ganz wesentlich vom Status der LSA zum Zeitpunkt des Überquerens beeinflusst. Das Fahrprofil beinhaltet „Beobachtungen“ des LSA-Status. In der Realität sind

¹In Ausnahmesituationen (z. B. Grün für Rechtsabbieger) kann eine Fahrtrichtung mehrfach grün und rot in einem Zyklus haben. Diese Spezialfälle werden in der Zusammenführung der Parameter der einzelnen Fahrtrichtungen berücksichtigt.

²Dieser Zeitpunkt kann z. B. der 01.01.1970 analog zum UNIX Zeitstempel sein, wobei die Wahl eines Zeitpunktes zu weit in der Vergangenheit Nachteile hat, welche in Abschnitt 6.1.2 beschrieben werden.

diese Messungen fehlerbehaftet: Fehler der Fahrzeugsensorik, Fehlverhalten von Fahrern an der Kreuzung oder sonstige Störungen an der Kreuzung (z. B. Rückstau, Unfall) führen zu fehlerhaften Beobachtungen des LSA-Status. Ein Fahrzeug ist z. B. zu einem Stopp bei Grün gezwungen, wenn die Kreuzung durch andere Fahrzeuge in der Kreuzung nicht befahrbar ist. Daher wird im Folgenden die Beobachtungen als Schätzung für den Zustand der LSA zu einem bestimmten Zeitpunkt betrachtet und durch das Zirkumflex-Zeichen ($\hat{}$) kenntlich gemacht.

Fahrzeuge ohne Stopp an einer Kreuzung beobachten lediglich zum Zeitpunkt des Überquerens der Haltelinie den Zustand grün der LSA:

$$\hat{t}_{gruen} = t_{pass}, \quad (6.1)$$

wobei t_{pass} der Zeitpunkt ist, an dem das Fahrzeug die Haltelinie passiert.

Für den Fall, dass ein Fahrzeug an der Kreuzung anhalten musste, kann aus dem Fahrprofil sowohl die Beobachtung über den Grünzeitpunkt \hat{t}_{gruen} als auch über die Rotzeit und den Start des Zyklus extrahiert werden:

$$\hat{t}_{rot} = t_{stop} \quad (6.2)$$

$$\hat{t}_{zyklusStart} = t_{start} - f(d_{Haltelinie}), \quad (6.3)$$

wobei t_{stop} der Zeitpunkt des Anhaltens an der Haltelinie, t_{start} der Zeitpunkt der Beschleunigung des Fahrzeugs nach dem Stopp, $d_{Haltelinie}$ die Distanz in Metern zur Haltelinie und die Funktion $f(x)$ zur Beschreibung der Zeit für den Abfluss einer Warteschlange der Länge x an der Kreuzung ist.³

Falls ein Rückstau an der LSA existiert, sind Fahrzeuge trotz des Status grün der LSA zum Anhalten gezwungen, wodurch die Schätzung \hat{t}_{rot} fehlerhaft ist. Diese Schätzungen werden durch TLSE für den Fall verworfen, dass $f(d_{Haltelinie})$ kleiner als die Standzeit $t_{start} - t_{stop}$ des Fahrzeugs ist.

6.1.2 Schätzung der Umlaufzeit durch Optimierung

Für die Schätzung der Umlaufzeit wird die Menge $\hat{T}_{zyklusStart} = \{\hat{t}_{zyklusStart_1}, \dots, \hat{t}_{zyklusStart_n}\}$ mit $n \in \mathbb{N}$ der Schätzungen für den Zeitpunkt des Zyklusstarts (zeitlich aufsteigend sortiert) aus dem vorherigen Abschnitt verwendet.

³Diese Funktion kann aus den Fahrprofilen für jede Fahrtrichtung abgeleitet werden.

Auf der Basis von $\hat{T}_{zyklusStart}$ berechnet TLSE die Länge des Zyklus lz und den Offset dt , wie im Folgenden beschrieben.

Zwei Elemente aus $\hat{T}_{zyklusStart}$ sind entweder Schätzungen für den gleichen oder unterschiedliche Zyklusstarts. Die Menge aller Zyklusstarts mit mindestens einer Schätzung ist definiert als $Z = \{z_1, \dots, z_m\}$ mit $m \in \mathbb{N}$ und $m \leq n$. Für einige Zyklen in der Realität kann es passieren, dass keine Schätzungen von Fahrzeugen vorliegen und diese daher nicht in Z enthalten sind. TLSE kann diese fehlenden Messungen erkennen und bei der Schätzung der Zykluszeit berücksichtigen.

TLSE berechnet jede Zyklusstartzeit $z \in Z$ aus den Beobachtungen aus $\hat{T}_{zyklusStart}$, die zu dem Zyklus z gehören. Dazu wird zunächst jede Schätzung $\hat{t}_{zyklusStart_i}$ dem entsprechenden Zyklus z zugeordnet. TLSE bildet dazu mittels hierarchischem Clusterverfahren Gruppen aus den Elementen $\hat{t}_{zyklusStart_1}, \dots, \hat{t}_{zyklusStart_k}, k \in \mathbb{N}$, indem ein neues Cluster gebildet wird, sobald die Distanz zwischen den Elementen einen bestimmten Grenzwert (z. B. einige Sekunden) überschreitet. Nachdem die Cluster aus Zyklusstartzeiten vorhanden sind, berechnet TLSE den mittleren Zyklusstartzeitpunkt $\bar{t}_{zyklusStart_z}$. Darauf basierend wird die Zykluslänge lz_i als Differenz zwischen den Startzeiten der aufeinander folgenden Zyklen $\bar{t}_{zyklusStart_{i+1}} - \bar{t}_{zyklusStart_i}$ für $i = \{1, \dots, m-1\}$ berechnet.

Wie bereits oben beschrieben, kann es passieren, dass einige reale Zyklen nicht Teil der Menge der beobachteten Zyklen Z sind. Daher überprüft TLSE für jede Zykluslänge, ob die Bedingung $lz_i \approx x \times \min(lz_1, \dots, lz_{m-1})$, für alle $x \in \mathbb{N}$ gilt. Falls dies der Fall ist, dann wird die Länge des Zyklus lz_i auf lz_i/x gesetzt.

Wenn eine exakte Zyklusstartzeit $t_{zyklusStart_i}$ und eine exakte Zykluslänge lz_i bekannt wären, dann könnte der Offset dt der Phase einer Fahrtrichtung zur Referenzzeit als Rest der Division der Zyklusstartzeit (eine große Zahl von mehreren hundert oder tausenden Sekunden) durch die Zykluslänge (eine kleine Zahl von einigen zehn Sekunden) berechnet werden. Allerdings ist diese Modulo-Berechnung anfällig für sehr kleine Abweichungen (z. B. kleiner als eine Sekunde) von lz_i , sodass diese bereits zu großen Fehlern von dt führen. Daraus folgt, dass die Modulo-Berechnung keine Lösung für eine zuverlässige Schätzung der LSA-Parameter ist. TLSE berechnet daher aus der Menge aller Zykluslängen lz_i eine Zykluslänge lz_{opt} , für die gilt, dass der mittlere quadratische Fehler der Offsets $dt_i = \bar{t}_{zyklusStart_i} \bmod lz_{opt}$ minimal wird:

$$\begin{aligned} \text{minimiere}_{lz \in \vec{X}} \quad & \sum_{i=1}^m (dt_i - \bar{dt})^2, \\ \text{mit } dt_i = & \bar{t}_{zyklusStart_i} \pmod{lz}, \\ \bar{dt} = & (1/m) \times \sum_{j=1}^m (dt_j \pmod{lz}) \end{aligned} \quad (6.4)$$

Der Lösungsraum für die Optimierung ist definiert als $\vec{X} = [\min(lz_1, \dots, lz_{m-1}), \max(lz_1, \dots, lz_{m-1})]$. Abbildung 6.2 stellt den Nutzen der Optimierung der Zykluslänge (rechte Seite) gegenüber eines einfachen gleitenden Mittels der Zykluslänge und der daraus resultierenden Offsets (linke Seite) dar.




Abbildung 6.2: Zykluslänge und Offset für 100 normalverteilte Zyklusstartzeiten mit $\mu = n \cdot 70 + dt$ und $\sigma = 10$ und $n \in \{1, \dots, 100\}$ (links). Zykluslänge und Offset nach Optimierung der Offsets (rechts). Der reale Offset des Zyklusstarts dt ist 20 s.

Nach der Optimierung stehen nun die Zykluslänge lz und der Offset dt zur Verfügung. Mittels dieser Werte und dem Referenzpunkt t_{ref} können nun optimierte Zyklusstartzeiten durch lineare Extrapolation berechnet werden. Zusätzlich wird die Standardabweichung der Zykluslänge σ_{lz} und des Offsets σ_{dz} berechnet.

6.1.3 Schätzung der Länge der Grünzeit

Sind die Länge des Zyklus lz und die Verschiebung des Zyklus dt gegeben, wird nun die Länge der Grünzeit lg (und daraus die Länge der Rotzeit $lr = lc - lg$) berechnet. In

diesem Abschnitt wird beschrieben, wie die Menge von Beobachtungen für den Status grün $\hat{T}_{gruen} = \{\hat{t}_{gruen_1}, \dots, \hat{t}_{gruen_s}\}$ und den Status rot $\hat{T}_{rot} = \{\hat{t}_{rot_1}, \dots, \hat{t}_{rot_t}\}$ der Fahrzeuge mit $s, t \in \mathbb{N}$ verarbeitet werden.

Die Idee dabei ist, die relative Zeit der Beobachtungen der Fahrzeuge zum Zyklusstart zu berechnen, um anschließend mittels Histogrammanalyse (siehe Abbildung 6.3) auf die Länge der Grünzeit lg zu schließen. Die grünen (roten) Balken geben dabei die Anzahl der Beobachtungen für den Status grün (rot) zu diesem Zeitpunkt im Zyklus an. Dabei ist eine Beobachtung des Status grün 10 s nach Zyklusstart ein Indikator für eine Grünzeit im Intervall vom Zyklusstartzeitpunkt bis zu 10 s. Deshalb trägt diese Beobachtung zu den Balken vom Zyklusstart bis zu 10 s bei. Analog dazu ist eine Beobachtung für den Status rot bei 10 s ein Indikator für eine Rotzeit von 10 s bis zum Zyklusende.




Abbildung 6.3: Histogramm zur Schätzung der Länge der Grünzeit/Rotzeit

In Abhängigkeit der charakteristischen Eigenschaften des Histogramms wird lg entweder als Zeitpunkt definiert, an dem eine größere Anzahl an Beobachtungen für den Status rot als für den Status grün existieren, oder, für den Fall, dass rote und grüne Balken keine Überschneidung haben, als Mittelpunkt zwischen der letzten grün und der ersten rot Beobachtung berechnet.

Um diese Histogramme zu berechnen, werden die Beobachtungen für grün und rot in Relation zum letzten Zyklusstartzeitpunkt t_j relativ zur Beobachtung gesetzt. Als Startzeitpunkte könnten einfacherweise die mittleren Schätzungen $\bar{t}_{zyklusStart}$ genutzt werden, allerdings bietet sich an, auf Basis der optimierten Zykluslänge und des Offsets genauere Startzeiten $T_S = \{t_{S_1}, \dots, t_{S_n}\}$ zu berechnen:

$$t_{S_i} = t_{ref} + dt + lc \cdot i, \text{ with } i \in \{1, \dots, n\} \quad (6.5)$$

Weiterhin erlaubt dieser Ansatz die Verwendung von Beobachtungen des Status grün, auch wenn für den Startzeitpunkt vor der Beobachtung keine Schätzung vorliegt, da der Startzeitpunkt dennoch mittels Gleichung 6.5 berechnet werden kann.

6.2 Zusammenführung der spezifischen LSA-Parameter der Fahrrichtungen

Durch LSA kontrollierte Knotenpunkte im Verkehrsnetz steuern den Verkehrsfluss von einzelnen Fahrrichtungen und sorgen für einen sicheren Verkehrsablauf. Dazu haben nicht verträgliche Verkehrsströme zu unterschiedlichen Zeiten, verträgliche Verkehrsströme zur gleichen Zeit das Recht zu fahren. Durch diese verkehrstechnischen Vorgaben sind die Schätzungen der LSA-Parameter für unterschiedliche Fahrrichtungen entweder ähnlich (für verträgliche Verkehrsströme) oder komplementär (für nicht verträgliche Verkehrsströme).

Das Ziel ist es nun, die Schätzung der LSA-Parameter einer Fahrrichtung durch den Vergleich mit den LSA-Parametern der anderen Fahrrichtungen zu stützen. Dazu werden zunächst für jede Fahrrichtung die verträglichen Fahrrichtungen festgestellt und die Schätzung der LSA-Parameter mit den „Beobachtungen“ der jeweils anderen Fahrrichtung verbessert. Dies ist möglich, da die LSA-Parameter von verträglichen Fahrrichtungen gleich sein müssen. Bei nicht verträglichen Fahrrichtungen unterscheiden sich die LSA-Parameter unter der Begebenheit, dass die Grünzeiten der Fahrrichtungen keine zeitliche Überlappung haben dürfen und die Zwischenzeiten am Knotenpunkt beachtet werden müssen. Die Länge einer Grünzeit einer Fahrrichtung kann also durch das Wissen über den Beginn der Grünzeit von nicht verträglichen Fahrrichtungen angepasst werden (oder umgekehrt bei entsprechender Validität). Im ersten Schritt werden also die Schätzungen der LSA-Parameter der einzelnen Fahrrichtungen mit den Schätzungen der anderen Fahrrichtungen verglichen, um verträgliche und nicht verträgliche Fahrrichtungen zu identifizieren. Bedingt verträgliche Fahrrichtungen haben entweder eine eigene Phase (realisiert als nicht verträglich) oder haben in einer anderen Phase gemeinsam mit anderen Fahrrichtungen ihre Grünzeit (realisiert als verträglich). Das heißt, verkehrstechnisch sind die Fahrrichtungen zwar bedingt verträglich, technisch

umgesetzt werden diese jedoch entweder als abgesichert oder als nicht abgesichert. Abschnitt 6.2.1 beschreibt den Vergleich der geschätzten LSA-Parameter.

Im zweiten Schritt werden die LSA-Parameter von verträglichen Fahrrichtungen zusammengefügt. Dabei werden die einzelnen Schätzungen der LSA-Parameter mit der Standardabweichung gewichtet. Dargestellt ist der Prozess in Abschnitt 6.2.2. Im dritten Schritt wird in Abschnitt 6.2.3 abschließend die Berechnung des gesamten Phasenplans durch Kombination der bereits zusammengeführten LSA-Parameter aller verträglichen Fahrrichtungen beschrieben. Dabei ist das Ziel, die berechneten Grünzeiten und Zwischenzeiten auf die Umlaufzeit der LSA abzubilden und so eine weitere Verbesserung der Einzelschätzungen zu erreichen.

6.2.1 Identifikation von verträglichen und nicht verträglichen Fahrrichtungen

Zur Identifikation von verträglichen und nicht verträglichen Fahrrichtungen muss die Schätzung der LSA-Parameter der einzelnen Fahrrichtungen jeweils miteinander verglichen werden. Dabei wird zunächst eine Matrix $M_{i,j}$ mit $i, j \in 1, \dots, n$ und n der Anzahl der Fahrrichtungen aufgestellt, wobei das Element an der Position (i, j) der Ähnlichkeit zwischen den LSA-Parametern, berechnet als Tupel von $lg_i - lg_j$ und $dt_i - dt_j$, der Fahrrichtungen i und j entspricht. Anschließend werden Fahrrichtungen anhand ihrer Ähnlichkeit mittels eines Schwellenwertes zusammengefasst. Daraus folgen die Gruppen g_1, \dots, g_m mit $m < n \in \mathbb{N}$ von Fahrrichtungen.

6.2.2 Zusammenführung von verträglichen Fahrrichtungen

Sind zwei Fahrrichtungen einer Gruppe zugeordnet, wird also angenommen, dass die Fahrrichtungen in einer Phase sind und folgerichtig die gleiche Startzeit und Länge der Grünzeit besitzen, dann werden die Einzelmessungen der Fahrrichtungen zusammengeführt, um eine genauere Schätzung der LSA-Parameter zu erreichen. Dazu werden die Berechnungsschnitte, wie bereits für einzelne Fahrrichtungen beschrieben (siehe Abschnitt 6.1), mit den Beobachtungen der Fahrzeuge für die Menge der verträglichen Fahrrichtungen aus der Gruppe g_i durchgeführt. Dabei ist zu erwähnen, dass das Extrahieren der Beobachtungen nicht erneut durchgeführt werden muss. Zunächst wird die Schätzung der Umlaufzeit und anschließend die Schätzung der Grünzeit durchgeführt. Nach Durchführung der Berechnung existieren genauere Schätzungen der LSA-Parameter für die zusammengeführten Fahrrichtungen, welche durch eine Erhöhung der

Anzahl der verfügbaren Messungen erreicht wird. Es stehen nach dem Zusammenfügen aller verträglichen Fahrtrichtungen in jedem Zeitschritt die Zykluslängen $lz_i(t)$, die Offsets $dt_i(t)$ und die dazugehörigen Standardabweichungen $\sigma_{lz,i}(t)$ und $\sigma_{dt,i}(t)$ zur Verfügung. Dabei sind $lz_i(t)$, $\sigma_{lz,i}(t)$ und $\sigma_{dt,i}(t)$ Abbildungen des Zeitpunktes t auf dem zu diesem Zeitpunkt vorhandenen Schätzwert bzw. die Standardabweichung. Der Index $i \in \{1, \dots, m\}$ symbolisiert dabei die entsprechende Fahrtrichtungsgruppe.

6.2.3 Zusammenführung von nicht verträglichen Fahrtrichtungen

Das Zusammenführen der nicht verträglichen Fahrtrichtungen geschieht auf Basis der bereits zusammengeführten Fahrtrichtungen aus Abschnitt 6.2.2. Im Folgenden wird der Prozess des Zusammenführens in drei Schritten beschrieben. Zunächst werden die Zykluslängen der Fahrtrichtungen abgeglichen, dann die Schätzungen für die Länge der Grünzeiten adaptiert und im letzten Schritt die Offsets angepasst.

Im ersten Schritt werden die Schätzungen für die Zykluslänge $lz_1(t), \dots, lz_m(t)$ mithilfe der Standardabweichungen $\sigma_{lz,1}(t), \dots, \sigma_{lz,m}(t)$ verknüpft. Es liegt nun die Annahme zu Grunde, dass die Zykluslänge aller Fahrtrichtungen an einem Knotenpunkt im Straßennetz gleich ist. Also muss

$$lz_r(t) = lz_m(t) \forall r = 1 \dots m - 1, \quad (6.6)$$

gelten, wobei erneut m die Anzahl der Fahrtrichtungen ist. Mittels der Bedingungen aus der Gleichung 6.6 und den jeweils zugehörigen Standardabweichungen ergibt sich die zusammengeführte Zykluszeit $\bar{lz}(t)$ zum Zeitpunkt t durch folgende Berechnungsvorschrift:

$$\bar{lz}(t) = \frac{1 \sum_{i=1}^m \frac{lz_i(t)}{\sigma_{lz,i}^2(t)}}{m \sum_{i=1}^m \frac{1}{\sigma_{lz,i}^2(t)}} \quad (6.7)$$

In Gleichung 6.7 wird das gewichtete arithmetische Mittel aller Schätzungen der Zykluslänge seit dem Zeitpunkt T bestimmt, wobei die Annahmen über die Gleichheit der Schätzungen der Zykluslänge gelten.

Im nächsten Schritt werden die letzten Schätzungen der Länge der Grünzeiten $lg_1(t), \dots, lg_m(t)$ zum Zeitpunkt t mittels linearem Gleichungssystem zusammengeführt.

Dabei hat das Gleichungssystem die Form $\mathbf{Ax} = \mathbf{y}$. Weiterhin ist \mathbf{w} eine diagonale Kovarianzmatrix mit Werten $\sigma_{lg,i}^2(t)$, wobei $i = 1, \dots, m$ ist. Die Idee dieses Gleichungssystems ist es, die Korrelation zwischen Grünzeiten und der Zykluslänge $\bar{lz}(t)$ abzubilden und mithilfe der Methode zur Minimierung der Fehlerquadratsumme zu lösen, d. h., x minimiert den Ausdruck $\min_x (\mathbf{y} - \mathbf{Ax})^T \mathbf{w}^{-1} (\mathbf{y} - \mathbf{Ax})$. Begründet liegt das Aufstellen dieses Gleichungssystems in der Tatsache, dass die Summe der einzelnen Grünzeiten plus Räumzeiten der Zykluszeit entsprechen muss. Die vorgeschriebene Räumzeit zwischen den Phasen wird im Folgenden mit r bezeichnet.

$$\mathbf{A} = \begin{pmatrix} lg_1(t) & 0 & \dots & 0 \\ 0 & lg_2(t) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & lg_m(t) \\ lg_1(t) + r & lg_2(t) + r & \dots & lg_m(t) + r \end{pmatrix} \quad (6.8)$$

$$\mathbf{y} = \begin{pmatrix} lg_1(t) \\ lg_2(t) \\ \vdots \\ lg_m(t) \\ \bar{lz}(t) \end{pmatrix}, \quad \mathbf{w} = \mathbf{I} \begin{pmatrix} \sigma_{lg,1}^2(t) \\ \sigma_{lg,2}^2(t) \\ \vdots \\ \sigma_{lg,m}^2(t) \\ \sigma_{lz}^2(t) \end{pmatrix} \quad (6.9)$$

In Gleichung 6.8 stellt Matrix A die Modellvorschrift dar, die zum einen alle $lg_i(t)$, gewichtet mit dem Kehrwert der Varianz, auf sich selbst und zum anderen die Summe aller Schätzungen der Grünzeit auf die Länge der Zykluszeit abbildet. Dabei wird nach jeder Phase die Räumzeit r berücksichtigt, wobei in [fSuV10] die Richtlinien für die Wahl der Räumzeit in Abhängigkeit der Größe des Knotenpunktes beschrieben sind. Gleichung 6.9 zeigt die dazugehörige Kovarianzmatrix \mathbf{w} , dargestellt als Vektor, multipliziert mit der Identitätsmatrix I . Der Vektor besteht aus den Varianzen der $lg_i(t)$ und der Varianz der mittleren Zykluszeit $\bar{lz}(t)$. Nach dem Lösen des Gleichungssystems stehen nun angepasst Schätzungen für die Grünzeiten $\bar{lg}_i(t)$ zur Verfügung.

Analog dazu wird im letzten Schritt ein lineares Gleichungssystem zur Zusammenführung der Schätzungen der Offsets $dt_1(t), \dots, dt_m(t)$, den dazugehörigen Standardabweichungen $\sigma_{dt,1}(t), \dots, \sigma_{dt,m}(t)$ und den berechneten Grünzeiten $\bar{lg}_i(t)$ aufgestellt. Die Idee ist, mittels dieses Gleichungssystems den Zusammenhang des Offsets, welcher den Beginn einer Phase beschreibt, der Grünzeit (inkl. Räumzeit) dieser Phase und des Offsets der nächsten Phase abzubilden. Der Zusammenhang wird allgemein als

$dt_i + lg_i + r = dt_{i+1} \Leftrightarrow lg_i + r = -dt_i + dt_{i+1}$ für $i = 1, \dots, m-1$ definiert. Dabei wird ohne Beschränkung der Allgemeinheit angenommen, dass $dt_i < dt_{i+1}$ und $dt_i \geq 0$ für alle $i = 1, \dots, m$.⁴ Für $i = m$ gilt der Sonderfall $lg_i + r - \bar{lz} = -dt_i + dt_1$. In den folgenden Gleichungen wird das entsprechende Gleichungssystem dargestellt.

$$\mathbf{A} = \begin{pmatrix} dt_1(t) & 0 & \dots & 0 \\ 0 & dt_2(t) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & dt_m(t) \\ -dt_1(t) & dt_2(t) & 0 & 0 \\ 0 & -dt_2(t) & dt_3(t) & 0 \\ \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & -dt_{m-1}(t) & dt_m(t) \\ dt_1(t) & 0 & 0 & -dt_m(t) \end{pmatrix} \quad (6.10)$$

$$\mathbf{y} = \begin{pmatrix} dt_1(t) \\ dt_2(t) \\ \vdots \\ dt_m(t) \\ lg_1(t) + r \\ lg_2(t) + r \\ \vdots \\ lg_{m-1}(t) + r \\ lg_m(t) + r - \bar{lz}(t) \end{pmatrix}, \quad \mathbf{w} = \mathbf{I} \begin{pmatrix} \sigma_{dt,1}^2(t) \\ \sigma_{dt,2}^2(t) \\ \vdots \\ \sigma_{dt,m}^2(t) \\ \sigma_{lg,1}^2(t) \\ \sigma_{lg,2}^2(t) \\ \vdots \\ \sigma_{lg,m-1}^2(t) \\ \sigma_{lg,m}^2(t) + \sigma_{\bar{lz}}^2(t) \end{pmatrix} \quad (6.11)$$

In Gleichung 6.10 stellt Matrix A erneut die Modellvorschrift dar, bestehend aus einer Abbildung aller $dt_i(t)$ auf sich selber und der Abbildung der Summe aufeinander folgender Offsets. Der Vektor \mathbf{y} und die Matrix \mathbf{w} sind in Gleichung 6.11 dargestellt. Nach Lösung des Gleichungssystem können durch alle Fahrtrichtungen gestützte Offsets $\bar{dt}_i(t)$ durch Einsetzen berechnet werden.

⁴Durch Sortierung der dt_i nach dem Offset und Addition mit der Zykluslänge kann in der Implementierung dieser Fall erzeugt werden.

6.3 Evaluierung von TLSE

In diesem Abschnitt wird zunächst die Korrektheit von TLSE durch Vergleich des realen Status der LSA (aus der Simulation) zu jedem Zeitschritt (jede Sekunde) mit dem durch TLSE geschätzten Status der LSA verglichen. Der Anteil der Zeitpunkte, bei denen der geschätzte und reale Status gleich sind, gibt dabei die Korrektheit von TLSE an. Die Kombination der einzelnen LSA-Parameter (Zykluslänge, Offset und Länge der Grünzeit) bestimmt also die Korrektheit von TLSE. Daran anschließend wird der Fehler der einzelnen LSA-Parameter über der Simulationszeit analysiert. In diesem Zuge wird sowohl der Einschwingvorgang von TLSE als auch der Einfluss der Anzahl der Fahrzeuge untersucht, die ihre Beobachtungen (Fahrprofile) an den Server übermitteln. Die Ausstattungsrate der Fahrzeuge wird dabei von 100 % bis zu 5 % variiert.

Zu Beginn der Simulation startet TLSE mit einer leeren Datenbank, welche während der Simulationszeit (ein Schritt pro Sekunde) mit Fahrprofilen gefüllt wird. Darauf basierend schätzt TLSE die LSA-Parameter (Zykluslänge, Offset und Länge der Grünzeit) für alle Fahrtrichtungen zu jedem Zeitschritt. Der Systemreferenzpunkt t_{ref} , auf den sich der LSA-Parameter dt bezieht, ist der Startzeitpunkt der Simulation. In den Szenarien mit variabler Verkehrsstärke (Szenarien 3-5) liegt der Startzeitpunkt bei Mitternacht und einer geringen Verkehrsstärke, die monoton bis zur ersten Hauptverkehrszeit am Morgen steigt.

Im Folgenden untersuchen wir die Schätzung für den LSA Status der Phasen auf den Hauptfahrtrichtungen von Westen nach Osten und umgekehrt. Aufgrund der Korrelation der Phasen an einer Kreuzung sind die Ergebnisse auch für die Phasen der anderen Fahrtrichtungen repräsentativ. Abbildung 6.4 zeigt, in wie viel Prozent der Simulationszeit der Status der LSA korrekt geschätzt wurde (rote Balken), wenn in einem Fall 100 % und in dem anderen Fall nur 5 % der Fahrzeuge ihre Fahrprofile teilen. Das Mittel von zehn Durchläufen der Simulation und die jeweiligen Standardabweichungen sind auf der y-Achse dargestellt. Dabei wird die Schätzung der zweiten LSA aus West-Richtung nicht in die Auswertung einbezogen, da an dieser aufgrund des Schaltverhaltens keine Fahrzeuge anhalten und somit keine Schätzung existiert.

Die Ergebnisse zeigen eine Genauigkeit von über 90 % für die Szenarien 1-4 mit 100 % Ausstattungsrate. Und auch für die Szenarien 1 und 2 liegt die Korrektheit von TLSE für nur 5 % Ausstattungsrate bei über 90 %. Dies liegt zum einen an der Festzeitsteuerung, zum anderen aber auch an dem konstanten Verkehrsfluss in der Simulation. In den Szenarien 3 und 4 ist die Verkehrsstärke insbesondere zu Beginn der Simulation




Abbildung 6.4: Prozent der korrekten Schätzungen des LSA-Status für Simulationsszenarien mit 100 % und 5 % Penetrationsrate

sehr gering, wodurch TLSE eine längere Zeit zum Einschwingen benötigt. Um diesen Effekt genauer zu untersuchen, ist in Abbildung 6.4 ebenfalls die Korrektheit von TLSE nach 20 % der Simulationszeit in blau dargestellt. Zu diesem Zeitpunkt ist der Einschwingvorgang in den meisten Fällen abgeschlossen. Die Korrektheit von TLSE nach der Einschwingzeit ist in allen Szenarien gestiegen. Insbesondere stieg sie jedoch in den Szenarien 3 und 4, da die Verkehrsstärke zu Beginn der Simulation sehr gering ist. In diesen Szenarien steigt die Korrektheit um ca. 10 % auf 80,9 % in Szenario 3 bzw. 76,1 % in Szenario 4. In Szenario 5 erreicht TLSE lediglich ca. 50 % Korrektheit, woraus folgt, dass TLSE erwartungsgemäß für den Einsatz an LSA mit variablen Umlaufzeiten nicht geeignet ist.

Im nächsten Schritt wird der Fehler der Schätzung für die LSA-Parameter einzeln untersucht. Zunächst wird die Abweichung der Schätzungen zu den realen LSA-Parametern (bezogen aus der Simulation) für die Szenarien 1, 3 und 4 dargestellt. Dabei bedeutet eine positive Abweichung ein Überschätzen des entsprechenden LSA-Parameters und eine

negative Abweichung ein Unterschätzen des LSA-Parameters. Im Anschluss werden die Schätzungen für das Szenario 5 dargestellt, um die starke Varianz der LSA-Parameter zu verdeutlichen. Die Darstellung von Szenario 2 entspricht der von Szenario 1 und wird deshalb hier nicht abgebildet. Zunächst ist in Abbildung 6.5 die Abweichung für das Szenario 1 mit Festzeitsteuerung, konstantem Verkehrsfluss und 100 % Ausstattungsrate dargestellt.




Abbildung 6.5: Differenz von geschätzten und realen LSA-Parametern: Szenario 1 für eine LSA mit 100 % ausgestatteten Fahrzeugen bei einem konstanten Verkehrsfluss von 918 Fzg./Stunde

Nach einer kurzen Initialisierungsphase werden die Parameter Zykluslänge und Offset durch TLSE korrekt geschätzt, wobei die geschätzte Länge der Grünzeit zwischendurch um maximal eine Sekunde von der realen Länge der Grünzeit abweicht. Für eine Ausstattungsrate von 5 % ist der Fehler der LSA-Parameter in Abbildung 6.6 dargestellt. In der Abbildung ist zu erkennen, dass die Phase des Einschwingvorgangs im Vergleich zu dem Szenario mit einer Ausstattungsrate von 100 % deutlich länger dauert, die Schätzung der LSA-Parameter anschließend jedoch genauso konstant ist.

Bei der tageszeitabhängigen Steuerung (Szenario 3) und variablem Verkehrsfluss ist die Initialisierungsphase aufgrund des geringen Verkehrsflusses im Vergleich zum vorher beschriebenen Szenario mit konstantem Verkehrsfluss zu Beginn länger. Dies ist in Abbildung 6.7 für eine Ausstattungsrate von 100 % und Abbildung 6.8 für eine Ausstattungsrate von 5 % zu erkennen. Mit steigendem Verkehrsfluss verbessert sich die




Abbildung 6.6: Differenz von geschätzten und realen LSA-Parametern: Szenario 1 für eine LSA mit 5% ausgestatteten Fahrzeugen bei einem konstanten Verkehrsfluss von 918 Fzg./Stunde




Abbildung 6.7: Differenz von geschätzten und realen LSA-Parametern: Szenario 3 für eine LSA mit 100% ausgestatteten Fahrzeugen bei variablem Verkehrsfluss von 918 Fzg./Stunde

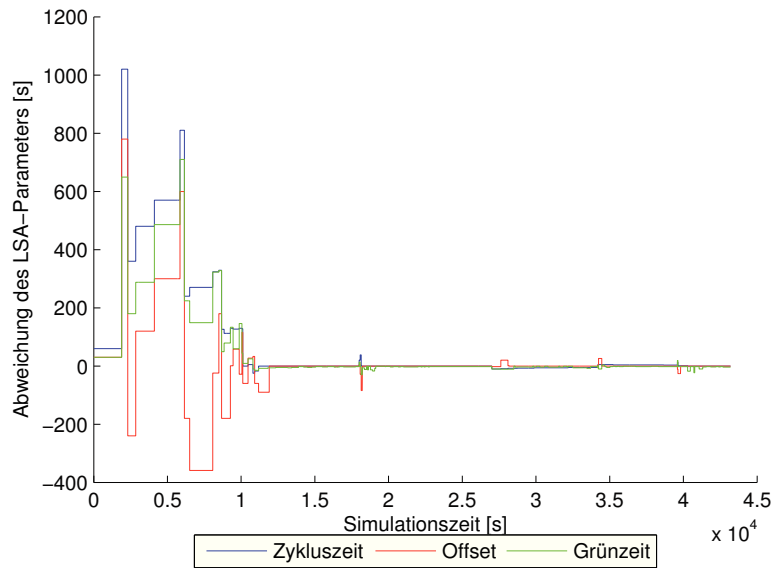


Abbildung 6.8: Differenz von geschätzten und realen LSA-Parametern: Szenario 3 für eine LSA mit 5 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss von 918 Fzg./Stunde

Schätzung der Parameter über die Simulationszeit. Weiterhin ist zu erkennen, dass TLSE die Schätzungen der Parameter insgesamt in weniger als zehn Minuten bei komplett wechselnden LSA-Parametern adaptiert. In Abbildung 6.9 ist ein Umschaltvorgang für eine Ausstattungsrate von 100 % und in Abbildung 6.10 für eine Ausstattungsrate von 5 % dargestellt.

In Szenario 4 variiert die Länge der Grünzeit für die einzelnen Fahrtrichtungen in jedem Umlauf. Dies wird erreicht, indem die Restgrünzeit aus der Nebenrichtung (Nord-Süd) der Hauptrichtung (West-Ost) zugewiesen wird (siehe Abschnitt 5.1). Die Umlaufzeit wird bei dieser Freigabezeitanpassung nicht beeinflusst und ist daher über der Simulationszeit konstant. Der Beginn der Grünzeit (Offset dt) ist für die Nebenrichtung ebenfalls konstant, für die Hauptrichtung variiert dt jedoch von Umlauf zu Umlauf um die Länge der Grünzeit, die von der Nebenrichtung freigegeben wurde. Die Abweichung der LSA-Parameter in Szenario 4 mit 100 % Ausstattungsrate ist für eine Kreuzung und einen Durchlauf in Abbildung 6.11 dargestellt. Abbildung 6.12 zeigt die Abweichung der LSA-Parameter für eine Ausstattungsrate von 5 %.

Für Szenario 4 ist eine Abweichung in der Schätzung der Länge der Grünzeit und des Offsets zu erkennen. Aufgrund der Freigabezeitanpassungen liegt der Fehler der Schätzung für die Grünzeit im Bereich der dynamischen Anpassung des Steuerungsalgorithmus.




Abbildung 6.9: Differenz von geschätzten und realen LSA-Parametern zur Umschaltzeit in Szenario 3 für eine LSA und 100 % ausgestattete Fahrzeuge

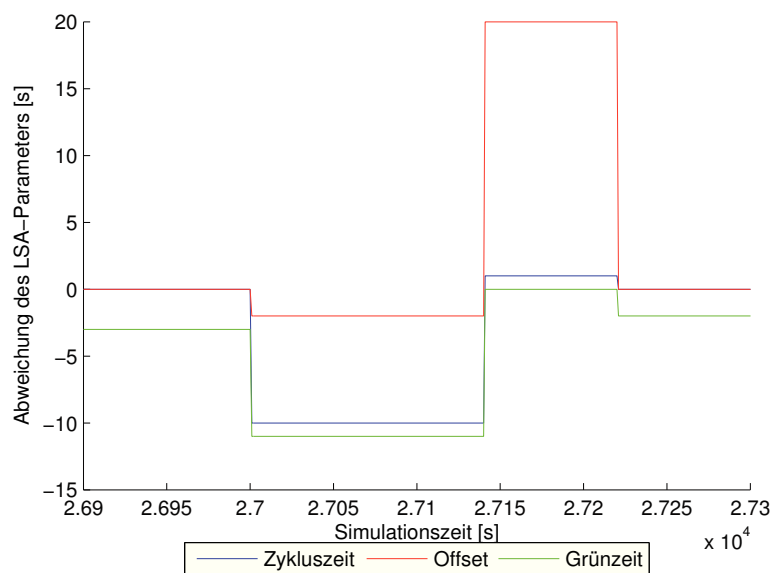


Abbildung 6.10: Differenz von geschätzten und realen LSA-Parametern zur Umschaltzeit in Szenario 3 für eine LSA und 5 % ausgestattete Fahrzeuge




Abbildung 6.11: Differenz von geschätzten und realen LSA-Parametern für Szenario 4 mit 100 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss




Abbildung 6.12: Differenz von geschätzten und realen LSA-Parametern für Szenario 4 mit 5 % ausgestatteten Fahrzeugen bei variablem Verkehrsfluss

Aufgrund dieser Anpassung schwankt für die Hauptverkehrsrichtung auch der Offset, da der Phasenbeginn abhängig von nicht-genutzter Freigabezeit der Nebenrichtung ist. Es ist also zu erkennen, dass der Beginn der Phase für die Hauptverkehrsrichtung nicht gut vorhergesagt werden kann, jedoch die Länge der Grünzeit niemals unterschätzt wird. Somit ist die Vorhersage über den Status der LSA bei Ankunft zu Beginn der Phase noch unsicher, das Ende der Phase kann jedoch sehr gut vorhergesagt werden. Für nur noch 5% ausgestattete Fahrzeuge wird die Schätzung der LSA-Parameter etwas schlechter, wobei das Verhalten jedoch analog zu dem Verhalten der Schätzung für 100% ausgestattete Fahrzeuge ist.




Abbildung 6.13: Differenz von geschätzten und realen LSA-Parametern für Szenario 5 mit 100% ausgestatteten Fahrzeugen bei variablem Verkehrsfluss

Im Vergleich zu den Schätzungen der LSA-Parameter in Szenario 4 ist TLSE in Szenario 5 erwartungsgemäß nicht in der Lage eine Regelmäßigkeit in den LSA-Parametern zu identifizieren. Aus diesem Grund variiert die Länge der einzelnen Schätzungen, wie in Abbildung 6.13 für eine Ausstattungsrate von 100% dargestellt. Das Ergebnis für eine Ausstattungsrate von 5% unterscheidet sich nicht in der Form und ist daher auch nicht dargestellt.

6.4 Zusammenfassung und Ausblick

In diesem Kapitel wurde der Algorithmus TLSE zur ursachenorientierten Analyse von Fahrprofilen vorgestellt. Das Ziel von TLSE ist die Schätzung der LSA-Parameter auf Basis von Fahrprofilen, die als „Beobachtungen“ des LSA-Zustands genutzt werden. Mittels der resultierenden Parameter kann der Status der LSA zu jedem Zeitpunkt in der Zukunft berechnet werden. TLSE ist dabei der erste veröffentlichte Algorithmus, der ausschließlich auf Basis von Fahrprofilen den aktuellen und zukünftigen Zustand der LSA schätzt. In anderen Veröffentlichungen wurde bereits das Potenzial zur Reduzierung des Kraftstoffverbrauchs mittels eines Fahrerinformationssystems auf Basis der Kenntnis über den LSA-Zustand in der Zukunft geschätzt. Die Kraftstoffeinsparung lag während der Zufahrt auf die LSA bei bis zu 20 %. Mit dieser Einsparung und dem Fakt, dass keine zusätzliche Hardware an der LSA installiert werden muss, kann TLSE einen großen Beitrag zur effizienteren Mobilität leisten.

TLSE erreichte in der Simulationsumgebung eine Genauigkeit von über 90 % für Festzeitsteuerungen und 80 % für verkehrsadaptive Steuerungen für LSA mit fester Umlaufzeit, wobei nur 5 % der verfügbaren Fahrprofile verwendet wurden. Für höhere Penetrationsraten zeigt die Simulation noch bessere Resultate. Während der Entwicklung und Analyse von TLSE wurden diverse weitere Forschungsfragen aufgeworfen, welche insbesondere mit der Realisierung von TLSE in der Realität untersucht werden sollten.

Zum einen wurde in Abschnitt 6.1.1 das Extrahieren von Beobachtungen aus Fahrprofilen beschrieben. Der beschriebene Algorithmus schätzt für Fahrzeuge mit einem Halt an der LSA den Zeitpunkt, an dem die eigene Fahrtrichtung die Freigabe bekommen hat. Dazu werden die Halteposition, der Start- und der Stoppzeitpunkt des Fahrzeugs verwendet. In der Realität können einige Effekte die Schätzung des Zeitpunkts der Freigabe beeinträchtigen. Beispielsweise können einzelne Fahrzeuge durch außergewöhnlich lange Reaktionszeiten die Schätzung beeinflussen. Ebenso gibt es immer wieder kleine Bewegungen in den Warteschlangen, bei denen Fahrzeuge einige Meter fahren bzw. rollen. Diese Bewegungen müssen gefiltert werden, um ein Fehlverhalten von TLSE zu vermeiden. Ebenso gefiltert werden müssen Situationen, in denen der Abfluss an der Kreuzung nicht gewährleistet ist, z. B. durch einen Rückstau im Kreuzungsbereich. In solchen Situationen sind die Schätzungen der Fahrzeuge nicht zu verwenden, weil die Schaltung der LSA nicht die maßgebende Ursache für die Bewegung der Fahrzeuge ist, sondern die Fahrzeuge auf der Kreuzung, welche die Bewegung der Fahrzeuge verhindern, der Grund dafür sind. Zusammenfassend müssen für die Umsetzung in der Realität Filter entwickelt werden, welche die Eingangsdaten für TLSE auf Gültigkeit überprüfen.

Darunter fällt auch eine Prüfung der Genauigkeit der Fahrzeuguhren, da eine nicht synchronisierte Fahrzeugzeit zu falschen Messungen des Start- und Stoppzeitpunktes führt und in der Folge zu falschen Schätzungen von TLSE.

Nach Filterung der Eingangsdaten werden die LSA-Parameter für die einzelnen Fahrtrichtungen durch TLSE geschätzt. Dabei muss die Anzahl der Freigabezeiten im letzten Zyklus berücksichtigt werden, da z. B. Rechtsabbieger zwei Freigabezeiten bekommen können. Das Erlernen dieser Situationen ist ein Baustein von TLSE, der in der Realität näher untersucht werden sollte. Weiterhin muss untersucht werden, welchen Einfluss offensichtliches Fehlverhalten von Fahrzeugen (z. B. das Überfahren der Kreuzung bei Rot) auf das Ergebnis von TLSE hat. Gegenstand von Untersuchungen sollte ebenfalls die Genauigkeit der Uhren in den LSA-Steuerungen und der Einfluss auf TLSE sein. Bei großen Abweichungen der internen LSA-Uhren müssen die Parameter für TLSE entsprechend angepasst werden.

Im letzten Schritt führt TLSE die Ergebnisse der einzelnen Fahrtrichtungen unter Berücksichtigung der einzelnen Freigabezeiten auf Basis der Richtlinien der LSA [fSuV10] zusammen. Verträgliche und nicht-verträgliche Verkehrsströme werden durch Analyse der LSA-Parameter der einzelnen Richtungen ermittelt. Dies ist ein vollständig neuer Ansatz und bedarf daher ebenfalls einer Evaluierung in der Realität. Weiterhin sind auch andere Ansätze denkbar. Beispielsweise könnten die Verkehrsströme anhand der Kreuzungsgeometrie auf Verträglichkeit untersucht werden. Dabei könnten mittels eines regelbasierten Systems (formulierte Regeln aus den gegebenen Richtlinien für LSA) mögliche LSA-Steuerungen abgeleitet und diese mit den LSA-Parametern der einzelnen Fahrtrichtungen abgeglichen werden. Im Gegensatz zu dem hier vorgestellten Verfahren wird dabei die Einhaltung der Richtlinien vorausgesetzt.

Zusammenfassend ist zu sagen, dass TLSE der erste Algorithmus zur Schätzung der LSA-Parameter an einer Kreuzung ist. Es wurden unterschiedliche Teilkomponenten entwickelt und simulativ evaluiert. Dabei war das Ziel, die Realisierbarkeit eines solchen Systems zu untersuchen und auch Penetrationsraten abweichend von 100 % zu evaluieren. Im Zuge dessen wurde TLSE auf Kreuzungen mit bestimmten LSA-Steuerungsverfahren beschränkt und die Funktionsweise für Penetrationsraten bis zu 5 % wurde untersucht.

Kapitel 7

TLCorA: Ursachenorientierte Analyse zum Lernen der Korrelation zwischen LSA

Als zweites System zur Prognose der zukünftigen Geschwindigkeit bei Zufahrt auf eine Kreuzung mit LSA wird in dieser Arbeit Traffic Light Correlation Analysis (TLCorA) vorgeschlagen. Auch dieses System setzt die Position von LSA als gegeben voraus, sodass TLCorA mit dem Wissen über den wesentlichen Einflussfaktor ebenfalls zu den ursachenorientierten Analysen zählt. Basierend auf den Statistiken aus den USA, die zeigen, dass ca. 75 % aller LSA koordiniert / korreliert sind [RIT], um den Verkehrsfluss zu steuern, verfolgt TLCorA die Idee, aus gesammelten Fahrprofilen die Korrelationen zwischen aufeinander folgenden LSA zu erkennen und während der Zufahrt eines Fahrzeugs auf eine LSA zu nutzen. Dazu wird die Korrelation zwischen einer zurückliegenden und der nächsten LSA sowie der aktuelle Geschwindigkeitsverlauf des berechnenden Fahrzeugs zwischen den LSA betrachtet.

Hierbei ist die Idee und gleichzeitig größte Aufgabe, den relativen Zeitpunkt der Überfahrt in der Phase der zurückliegenden LSA zu identifizieren. Angenommen, die Phasen der zurückliegenden und der vorausliegenden LSA sind korreliert, dann wird für alle Fahrzeuge mit ähnlichem relativen Zeitpunkt und einer ähnlichen Reisezeit zwischen den beiden LSA der Status der vorausliegenden LSA bei Ankunft gleich sein. TLCorA identifiziert also zunächst den relativen Zeitpunkt der Überfahrt in der Phase der zurückliegenden LSA, um dann aus einer Datenbasis Fahrprofile mit ähnlichem relativen Zeitpunkt zu finden. Für diese Menge von Fahrprofilen wird im dritten Schritt die Klassifizierung mittels DTW (siehe Kapitel 4) angewendet. Abschließend wird das aktuelle Fahrprofil des berechnenden Fahrzeugs mit den repräsentativen Fahrprofilen der Klassen verglichen und einer Klasse zugeordnet. Die Fahrprofile dieser Klasse sind die relevanten Fahrprofile der weiteren Berechnung. Der wahrscheinlichste Status an der vorausliegenden LSA wird dann als meist aufgetretener Status an der LSA der relevanten Fahrprofile

berechnet. Diese Information kann dann durch den Fahrer oder ein Fahrerassistenzsystem genutzt werden, um ein verbrauchsreduzierten Geschwindigkeitsverlauf in Abhängigkeit des Status zu berechnen.

Die Komplexität von Phasenplänen an großen Kreuzungen und Verkehrsleitsysteme zur ständigen Anpassung der LSA-Parameter können das Lernen der Parameter ohne weiteres Vorwissen über die Steuerungslogik für TLSE (Kapitel 6) unmöglich machen. TLCorA hingegen basiert ausschließlich auf der Korrelation aufeinander folgender LSA, sodass die Komplexität der Phasenpläne und die Anpassung von Verkehrsleitsystemen bei konstanter Korrelation keinen Einfluss auf den Algorithmus haben. Im Gegensatz dazu haben der Verkehrsfluss und die Distanz zwischen LSA keinen Einfluss auf TLSE, jedoch auf TLCorA. Wir schlagen daher zwei Systeme vor, die sich ergänzen, um an möglichst vielen LSA die Geschwindigkeit zum Ankunftszeitpunkt an der nächsten LSA schätzen können.

Der in diesem Kapitel beschriebene Algorithmus ist in [KWM12] veröffentlicht. Die Entwicklung des Algorithmus sowie die Implementierung und Auswertung ist maßgeblich durch den Autor dieser Arbeit durchgeführt worden.

Dieses Kapitel ist folgendermaßen strukturiert: In Abschnitt 7.1 wird im Detail beschrieben, wie TLCorA den relativen Zeitpunkt der Überfahrt und die relevanten Fahrprofile anderer Fahrzeuge aus der Datenbasis identifiziert. Anschließend werden unter Verweis auf die bereits vorgestellten Algorithmen zur Klassifizierung von Fahrprofilen mittels DTW (Kapitel 4) die Identifikation der relevanten Fahrprofile (siehe Abschnitt 7.1) und anschließend die Ergebnisse der Auswertung von TLCorA in Abschnitt 7.2 beschrieben.

Ein Überblick über die Berechnung des zukünftigen Geschwindigkeitsverlaufs während der Zufahrt auf eine durch LSA gesteuerte Kreuzung ist in Abbildung 7.1 dargestellt.

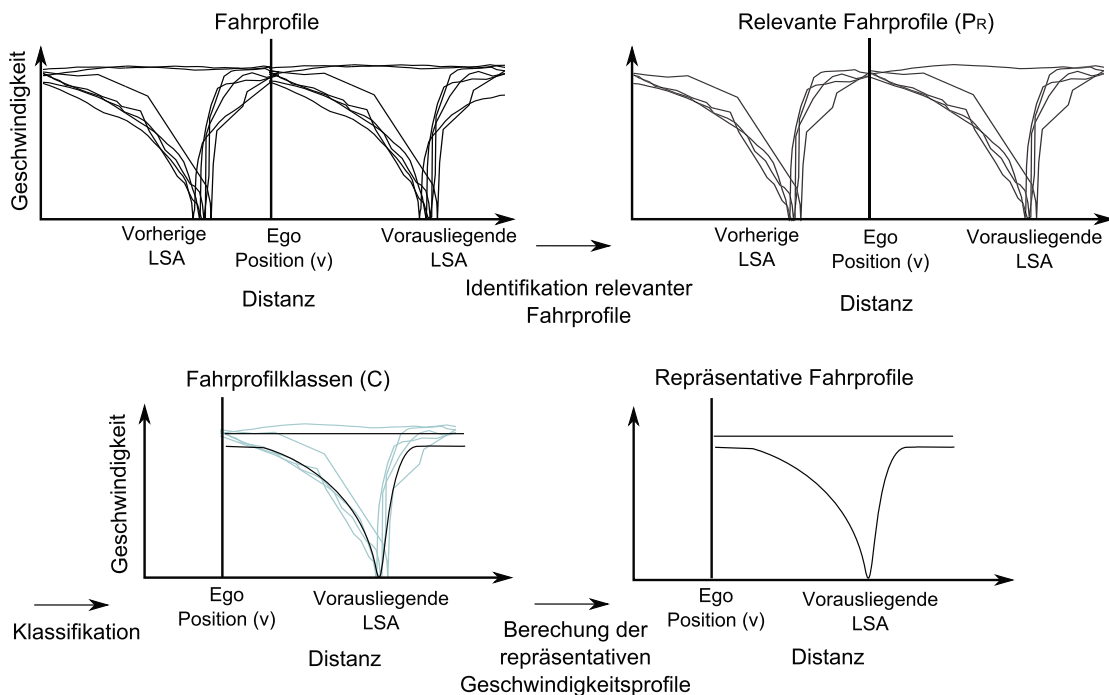


Abbildung 7.1: Schritte der Berechnung des zukünftigen Geschwindigkeitsverlaufs bei Zufahrt auf eine durch LSA gesteuerte Kreuzung.

7.1 Funktionsweise: Identifikation von relevanten Fahrprofilen

In diesem Abschnitt wird beschrieben, wie TLCorA zunächst die relative Zeit der Überfahrt in der Phase einer bereits zurückliegenden LSA im Fahrzeug berechnet. TLCorA bestimmt diese Zeit an der Position \vec{p} , wenn eine bestimmte Distanz d (z. B. mehrere hundert Meter) zur vorausliegenden LSA unterschritten ist. Der Parameter d ist entsprechend der benötigten Distanz der auf der Prognose aufsetzenden Applikation anzupassen. Zur Kraftstoffverbrauchsreduzierung ist das die Distanz, welche benötigt wird, um von der aktuellen Geschwindigkeit durch verbrauchsreduzierende Manöver das Fahrzeug zum Stillstand zu bringen. Im zweiten Schritt findet TLCorA Fahrzeuge aus der Datenbasis, die an der Position \vec{p} eine ähnliche relative Zeit zur Phase der zurückliegenden LSA hatten. Wir bezeichnen die Identifikation eines relativen Zeitpunkts zur Phase einer zurückliegenden LSA als *Synchronisation*.

Im Allgemeinen ist eine genaue Synchronisation mit der Phase nur dann möglich, wenn das Umschalten von rot nach grün aus dem Fahrprofil zu erkennen ist. Für den Fall, dass ein Fahrzeug die LSA ohne Stopp überquert, kann nur auf einen Zeitpunkt irgendwo in der Grünphase geschlossen, jedoch kann dieser nicht genauer bestimmt werden. Daher

ist die einzige Möglichkeit zur Synchronisation aus dem Fahrprofil eine zurückliegende LSA zu finden, an welcher das Fahrzeug stoppen musste, und den relativen Zeitpunkt zu dieser zu bestimmen.¹

Zu diesem Zweck identifiziert TLCorA aus dem eigenen Fahrprofil die letzte LSA L auf der Route, die das Fahrzeug zum Stillstand gebracht hat. Mit Hilfe der Position von L berechnet TLCorA die relative Zeit \hat{t}_r zum Phasenplan als Differenz der aktuellen Zeit, an der Position \vec{p} und der Zeit \hat{t}_{gruen} an L den Status von rot auf grün gewechselt hat. Dabei sind \hat{t}_r und \hat{t}_{gruen} erneut durch das Zirkumflex-Symbol ($\hat{}$) als Schätzungen markiert.

Aus dem Fahrprofil wird t_{gruen} durch TLCorA analog zu der Beschreibung in Abschnitt 6.1.1 bestimmt:

$$\hat{t}_{gruen} = t_{start} - f(d_{stopLine}), \quad (7.1)$$

wobei t_{start} der Zeitpunkt der Beschleunigung des Fahrzeugs nach dem Stopp, $d_{Haltelinie}$ die Distanz in Metern zur Haltelinie und f die Funktion zur Beschreibung der Abflussgeschwindigkeit an der Kreuzung ist.

Anschließend schätzt TLCorA die relative Zeit \hat{t}_r durch

$$\hat{t}_r = t(\vec{p}) - \hat{t}_{gruen}, \quad (7.2)$$

wobei $t(\vec{p})$ für den Zeitpunkt steht, an dem das Fahrzeug an Position \vec{p} ist.

Nach der Synchronisation des Fahrzeugs mit L identifiziert TLCorA Fahrprofile anderer Fahrzeuge, welche ebenfalls an L gehalten haben und dieselbe Route zur vorausliegenden LSA gefahren sind. Für diese Fahrprofile f_i berechnet TLCorA den relativen Zeitpunkt $t_{r_{f_i}}$ zum Phasenplan an Position \vec{p} . Falls $t_{r_{f_i}} - t_r \in B$, wobei B ein Zeitintervall ist, wird das entsprechende Fahrprofil zu der Menge der relevanten Fahrprofile T_R hinzugefügt. Auf Basis dieser Profile werden anschließend die Klassifizierung und Berechnung des repräsentativen Geschwindigkeitsverlaufs durchgeführt (siehe Abschnitt 4.2). Dabei wird zunächst DTW als Abstandsmaß für Geschwindigkeitsverläufe verwendet und anschließend werden durch Minimierung der Differenzen zwischen den Geschwindigkeitsverläufen der einzelnen Klassen die repräsentativen Geschwindigkeitsverläufe berechnet.

¹Unter Verwendung von Fahrzeug-zu-Fahrzeug Kommunikation könnte die Synchronisation ebenfalls durch ein Fahrzeug in der direkten Umgebung erfolgen und an das eigene Fahrzeug übertragen werden. Ebenfalls vorstellbar ist eine Verbesserung der Synchronisation im Fahrzeug durch den Vergleich der Synchronisationszeitpunkte zwischen Fahrzeugen.

Das Ergebnis dieser Berechnung ist eine Menge von repräsentativen Geschwindigkeitsverläufen mit Eintrittswahrscheinlichkeiten. Auf Basis dieser kann die Strategie des Heranfahrens an die LSA bestimmt werden, um z. B. den Kraftstoffverbrauch zu reduzieren.

7.2 Evaluierung von TLCorA

Im Folgenden wird TLCorA anhand von fünf Szenarien, welche in Abschnitt 5.2 beschrieben sind, evaluiert. Im ersten Schritt wird die Anzahl der repräsentativen Geschwindigkeitsverläufe bei der Zufahrt auf die Kreuzungen ausgewertet. Wenige, repräsentative Geschwindigkeitsverläufe bedeuten eine große Ähnlichkeit der relevanten Geschwindigkeitsverläufe und somit eine hohe Wahrscheinlichkeit, dass die LSA, wie berechnet, überfahren werden wird. Im zweiten Schritt wird der Zusammenhang der Anzahl der repräsentativen Geschwindigkeitsverläufe und der relativen Zeit an der zurückliegenden LSA untersucht. Die Hypothese ist, dass lediglich zu bestimmten relativen Zeiten mehrere und in einem bestimmten Zeitintervall lediglich ein repräsentativer Geschwindigkeitsverlauf entstehen. Im dritten Schritt wird die Wahrscheinlichkeit des wahrscheinlichsten, repräsentativen Geschwindigkeitsverlaufs in allen Szenarien analysiert. Dies hat wesentlichen Einfluss auf die Anwendung, welche die Daten nachher nutzt, da z. B. bei mehreren repräsentativen Geschwindigkeitsverläufen mit ähnlicher Wahrscheinlichkeit nur schwer eine verbrauchseffiziente Strategie zum Heranfahrens an die LSA berechnet werden kann. Die Hypothese hier ist, dass der wahrscheinlichste Geschwindigkeitsverlauf eine deutlich höhere Wahrscheinlichkeit in den Szenarien 1 bis 3 aufweist, als die Wahrscheinlichkeiten in den Szenarien 4 und 5. Dies ist in der steigenden Variabilität der eingesetzten Steuerungsprogramme begründet. Vor der Evaluation von TLCorA wird nun zunächst die Anwendung des Algorithmus auf die Simulationsdaten beschrieben.

Die Bestimmung der repräsentativen Geschwindigkeitsverläufe wird durch TLCorA bei einer Distanz von $d=150$ m vor jeder Haltelinie der vorausliegenden LSA auf Basis aller relevanten Geschwindigkeitsverläufe durchgeführt. In der Auswertung wird lediglich eine Hauptverkehrsrichtung (von Ost nach West) betrachtet, wobei die Ergebnisse für die Fahrtrichtung von West nach Ost vergleichbar sind. Die Fahrtrichtungen von Süden nach Norden und umgekehrt werden nicht betrachtet, da jeweils nur eine LSA auf der Strecke liegt und daher die Berechnung der Geschwindigkeitsverläufe mit TLCorA nicht angewendet werden kann. In weiteren Simulationen wurde die Berechnungsdistanz d bis zu 1500 m erweitert, wobei sich die Ergebnisse nicht signifikant von denen für $d=150$ m

unterscheiden. Lediglich die Berechnungsdauer erhöht sich, da die Ähnlichkeitsbestimmung der relevanten Fahrprofile aufgrund der Länge der Fahrprofile deutlich aufwendiger ist. Zur Unterscheidung von relevanten und nicht relevanten Geschwindigkeitsverläufen wurde ein Schwellenwert B eingeführt. Geschwindigkeitsverläufe, deren relative Zeit in dem Intervall $B = [-2,5 s, 2,5 s]$ zur relativen Zeit des aktuell betrachteten Geschwindigkeitsverlaufs liegen, werden als relevant markiert, wobei B nach empirischer Analyse für die hier untersuchten Szenarien gewählt wurde. Die Größe des Intervalls muss in Abhängigkeit der Menge der verfügbaren Geschwindigkeitsverläufe festgelegt werden und hat einen wesentlichen Einfluss auf die Anzahl der resultierenden repräsentativen Geschwindigkeitsverläufe. Weiterhin wurde die maximale Anzahl der relevanten Geschwindigkeitsverläufe in der Bestimmung der repräsentativen Geschwindigkeitsverläufe auf 50 Geschwindigkeitsverläufe begrenzt. Dabei werden zu jeder Berechnungszeit die zeitlich aktuellsten Geschwindigkeitsverläufe aus der Datenbasis verwendet. Dies senkt zum einen die Rechenzeit, sorgt zum anderen aber auch für die benötigte Anpassungsfähigkeit an Wechsel der LSA-Steuerung von TLCorA. Bei der Umsetzung von TLCorA in die Realität muss der Parameter in Abhängigkeit der Penetrationsrate evaluiert werden. In dieser Arbeit dient er in erster Linie dazu, den Berechnungsaufwand zu reduzieren, ohne zu viele Informationen zu reduzieren. Dabei hat sich die Anzahl von 50 Geschwindigkeitsverläufen als praktikabel erwiesen. Die Limitierung der Anzahl der verfügbaren Geschwindigkeitsprofile in der Datenbasis hat zur Folge, dass Fahrzeuge mit der gleichen relativen Zeit zur zurückliegenden LSA unterschiedliche, repräsentative Geschwindigkeitsverläufe und Wahrscheinlichkeiten erhalten können. Beim Clusterverfahren für relevante Geschwindigkeitsverläufe wird der Schwellenwert $T = 2 \times d$ in allen Szenarien gesetzt. Die zwölfstündigen Simulationen wurden jeweils zehn Mal durchgeführt.

Im Folgenden wird zunächst die Anzahl der repräsentativen Geschwindigkeitsverläufe (Cluster), berechnet durch TLCorA, für die LSA 2 bis 5 für alle Szenarien untersucht. LSA 1 ist hierbei ausgeschlossen, da es zu dieser keine zurückliegende LSA gibt und somit auch keine Korrelation berechnet werden kann. Dabei wird für jedes Fahrzeug in der Simulation vor jeder LSA die Anzahl der Cluster bestimmt und über alle Fahrzeuge eine Häufigkeitsanalyse durchgeführt. Die Ergebnisse sind in Abbildung 7.2 dargestellt.

In den Szenarien 1 und 2 mit Festzeitsignalprogramm entsteht in der Regel nur ein Cluster. Eine Ausnahme bildet der Fall der Zufahrt auf LSA 3 in Szenario 1. Der Grund für die entstehenden zwei bzw. drei Cluster ist die Korrelation von LSA 2 und LSA 3, welche zur Folge hat, dass Fahrzeuge am Ende der Warteschlange von LSA 2 keine Möglichkeit haben, LSA 3 in derselben Freigabezeit zu überqueren wie Fahrzeuge vorne in der Warteschlange. In diesem Fall besteht also eine Korrelation und eine solche ist

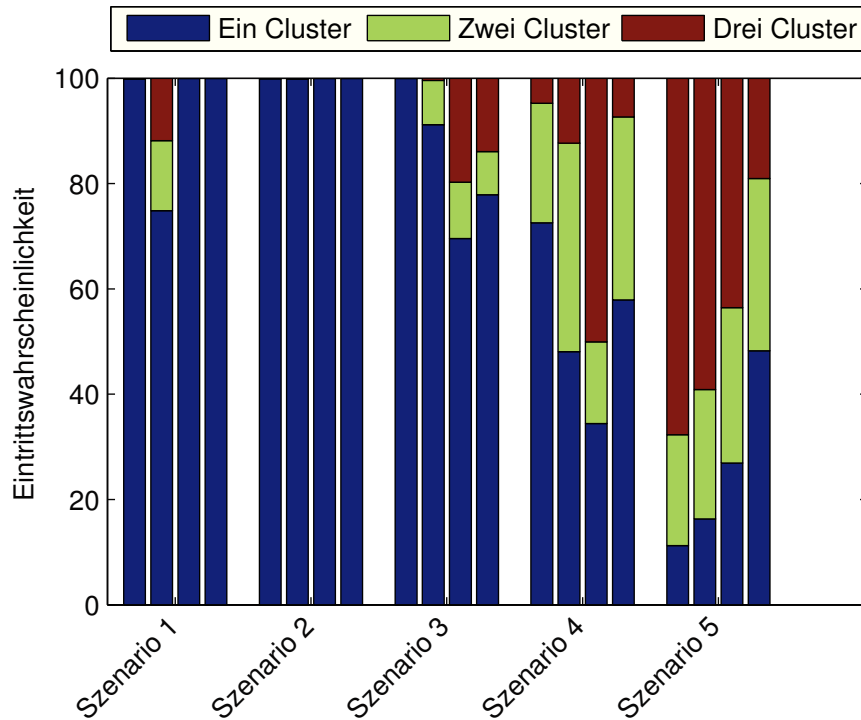


Abbildung 7.2: Anzahl der repräsentativen Geschwindigkeitsverläufe (Cluster) berechnet durch TLCorA für die LSA 2 bis 5 in allen Szenarien

von TLCorA auch detektierbar, allerdings sind die LSA nicht effizient aufeinander abgestimmt, wodurch mehr als ein Cluster entsteht. Durch eine Verkleinerung des Intervalls B ist in dieser Situation eine Reduzierung dieser Fälle zu erreichen. Allerdings wird dadurch auch die Anzahl der relevanten Fahrprofile in der Datenbasis verringert, was bei kleiner Datenbasis dazu führen kann, dass keine Prognose durchgeführt werden kann. Später werden wir allerdings noch zeigen, dass die Identifikation einer solchen Situation bereits genutzt werden kann, auch wenn zwei Cluster entstehen.

In Szenario 3 werden die Steuerungsprogramme der LSA tageszeitabhängig geschaltet. In Konsequenz entstehen mehrere Cluster. Zum einen aufgrund der Umschaltzeiten zwischen den einzelnen tageszeitabhängigen Steuerprogrammen, zum anderen durch nicht effiziente Korrelationen der LSA. Im Schnitt entsteht jedoch für ca. 80% der Berechnungen nur ein Cluster.

Die steigende Variabilität in Szenario 4 mit der mikroskopischen Anpassung der Freigabezeit hat zur Folge, dass Fahrzeuge mit gleicher relativer Zeit an der zurückliegenden LSA einen unterschiedlichen Status der vorausliegenden LSA vorfinden und somit

mehrere Cluster detektiert werden. Dies tritt insbesondere bei Fahrzeugen auf, die im Zeitraum der zusätzlichen Freigabezeit an der vorausliegenden LSA ankommen. Auch dieser Fall wird im Folgenden noch genauer untersucht, wenn der Einfluss der relativen Zeit an der letzten LSA auf die Vorhersage analysiert wird.

Für Szenario 5 entstehen in über 50 % der Fälle zwei oder mehr Cluster. Dies ist bereits ein Zeichen für die fehlende Korrelation der LSA in dem Szenario, welche aufgrund der Signalprogrammierung auch nicht direkt existiert, sondern nur indirekt durch einen konstanten und hohen Verkehrsfluss entstehen kann. Beispielsweise ist dies der Fall, wenn der Verkehrsfluss beider Fahrtrichtungen an die Grenzen der Kapazität des Knotenpunktes stößt. In diesem Fall würde die Freigabezeit beider Fahrtrichtungen in jedem Zyklus annähernd den Maximalwert erreichen und somit ein Determinismus in der Steuerung entstehen.

Eine Funktion im Fahrzeug, welche basierend auf den Ergebnissen von TLCorA eine Handlungsempfehlung an den Fahrer oder eine automatisierte effiziente Längsregelung umsetzen möchte, benötigt im besten Fall nur ein Cluster mit 100 % Eintrittswahrscheinlichkeit bei der Zufahrt auf die LSA. Der Ablauf der Funktion ist dadurch eindeutig. In der Regel entstehen jedoch mehrere Cluster mit unterschiedlichen Eintrittswahrscheinlichkeiten, auf welcher Basis die Funktion eine Entscheidung treffen muss. Im Folgenden wird untersucht, wie hoch die Eintrittswahrscheinlichkeit für das wahrscheinlichste Cluster in den unterschiedlichen Szenarien ist. Je höher die Eintrittswahrscheinlichkeit des wahrscheinlichsten Cluster, desto einfacher ist die Entscheidung für eine Handlungsanweisung oder Reaktion der Funktion. Sind die Eintrittswahrscheinlichkeiten für mehrere Cluster jedoch annähernd gleichverteilt, so ist eine fehlerfreie Funktion nicht zu realisieren.

In Abbildung 7.3 ist zunächst die empirische Verteilungsfunktion für die Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters in den Szenarien 1 und 2 dargestellt. Dabei ist zu erkennen, dass fast durchgehend eine Wahrscheinlichkeit von 100 % für das wahrscheinlichste Cluster gilt. Eine Ausnahme stellt dabei die LSA 3 in Szenario 1 aus bereits erwähnter schlechter Korrelation der LSA dar. Allerdings ist bereits auch zu erkennen, dass in diesem Szenario nur in weniger als 5 % der Fälle die Wahrscheinlichkeit für das wahrscheinlichste Cluster kleiner als 80 % ist. Mit den Szenarien 1 und 2 ist die Anwendbarkeit von TLCorA auf LSA mit fester Korrelation gezeigt.

Zur Analyse von TLCorA in den Szenarien 3 und 4 zeigt Abbildung 7.4 die empirische Verteilungsfunktion für die Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters




Abbildung 7.3: Empirische Verteilungsfunktion (EDF) der Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters für Szenario 1 (links) und Szenario 2 (rechts)

in diesen Szenarien. Im Vergleich zu den Szenarien 1 und 2 ist für alle LSA eine Verringerung der Eintrittswahrscheinlichkeit für das wahrscheinlichste Cluster zu erkennen, wobei in Szenario 3 für LSA 4 noch immer in 70 % aller Fälle die Eintrittswahrscheinlichkeit für das wahrscheinlichste Cluster bei 100 % liegt. Bei LSA 2 und LSA 3 liegt die Eintrittswahrscheinlichkeit sogar in über 90 % der Fälle bei 100 %.

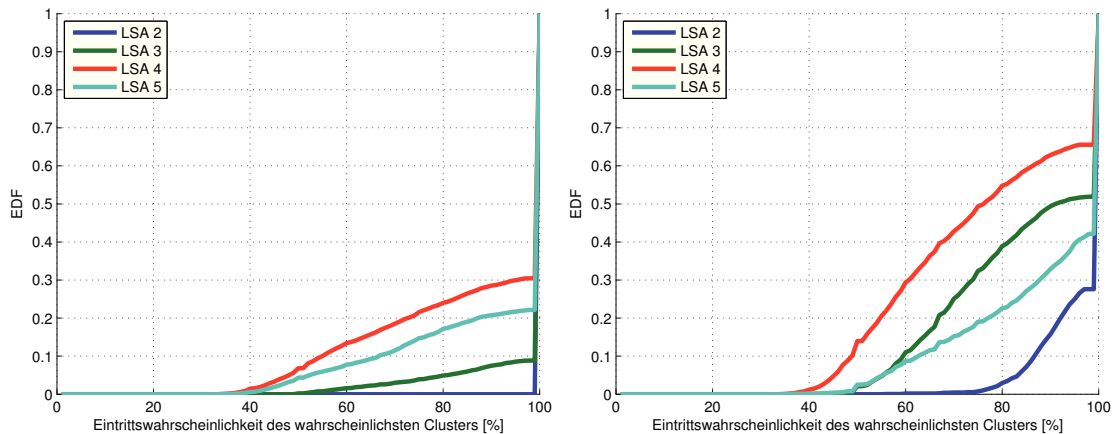


Abbildung 7.4: Empirische Verteilungsfunktion (EDF) der Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters für Szenario 3 (links) und Szenario 4 (rechts)

Für Szenario 4 ist in Abbildung 7.4 eine weitere Reduzierung der Eintrittswahrscheinlichkeiten für alle LSA zu erkennen. Für LSA 2 gilt in über 90 % der Fälle eine Eintrittswahr-

scheinlichkeit von über 80 %. Im Gegensatz dazu gilt für LSA 4 nur in ca. 40 % der Fälle eine Wahrscheinlichkeit von über 80 %. LSA 3 und LSA 4 liegen entsprechend zwischen diesen beiden Werten. Begründet werden diese Unterschiede in der LSA-Steuerung, die den Verkehrsfluss zwischen den LSA natürlich stark beeinflusst, wodurch es zur Bildung von Fahrzeuggruppen kommt. Als Konsequenz ist der Verkehrsstrom an LSA 2 und zum Beispiel LSA 5 vollkommen verschieden. Trotz der Reduzierung der Eintrittswahrscheinlichkeiten ist auch für das Szenario 4 zu erkennen, dass TLCorA auf entsprechende LSA-Steuerungen anwendbar ist.




Abbildung 7.5: Empirische Verteilungsfunktion (EDF) der Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters für das Szenario 5

In Szenario 5 (der Signalprogrammgebung) ist in Abbildung 7.4 für alle LSA eine weitere Reduzierung der Eintrittswahrscheinlichkeiten zu erkennen. Dabei sind insbesondere die Eintrittswahrscheinlichkeiten für LSA 2 bis 4 deutlich geringer als in den anderen Szenarien und TLCorA ist nur noch in ca. 30 % der Fälle anwendbar, wenn die Anforderungen einer Applikation an die Eintrittswahrscheinlichkeit von mindestens 80 % bestände. Es muss daher festgehalten werden, dass TLCorA für die Signalprogrammgebung in diesem Szenario nur begrenzt anwendbar ist.

Im nächsten Schritt wird der Einfluss des relativen Zeitpunkts in der Phase auf die Anzahl der resultierenden Cluster untersucht. Wie bereits oben beschrieben, ist die Hypothese, dass nur zu bestimmten Zeitpunkten relativ in der Phase mehrere Cluster entstehen und zu anderen Zeitpunkten die Vorhersage des wahrscheinlichsten Geschwindigkeitsprofils eindeutig ist, d. h., die Eintrittswahrscheinlichkeit des wahrscheinlichsten Clusters bei 100 % liegt. Das Ziel ist nun, mit der folgenden Analyse zu untersuchen, ob mit einer kleinen Veränderung des Geschwindigkeitsverlaufs die Eintrittswahrschein-

lichkeit für das wahrscheinlichste Cluster erhöht werden kann. Beispielsweise kann eine Verringerung der Geschwindigkeit, in einer Situation mit ungünstiger Korrelation, für eine Erhöhung der Eintrittswahrscheinlichkeit des Clusters sorgen, in welchem die Fahrzeuge stoppen mussten. Genauso kann eine Beschleunigung für das Gegenteil sorgen. Repräsentativ für die anderen Szenarien werden im Folgenden Szenarien 1 und 4 analysiert.




Abbildung 7.6: Einfluss der relativen Zeit zum Phasenbeginn auf die Anzahl der Cluster in Szenario 1

In Abbildung 7.6 ist auf der x-Achse die Zeit relativ zum Phasenbeginn der LSA aufgetragen, welche als Grundlage der Berechnung dient. Diese Zeit liegt für das dargestellte Szenario 1 zwischen 0 s und 140 s. Dies resultiert aus der Zykluszeit von 43 s (Eingangsparmeter der Simulation) in diesem Szenario und der räumlichen Distanz zwischen der referenzierten und der vorausliegenden LSA. Somit ist auch an der Zeit relativ zum Phasenbeginn zu erkennen, welche der zurückliegenden LSA als Referenz für die Berechnung dient. Auf der y-Achse ist die Anzahl der resultierenden Cluster für die vorausliegende LSA dargestellt. Für Szenario 1 ist dabei zu erkennen, dass lediglich für LSA 3 und lediglich bei einer relativen Zeit zum Phasenbeginn von ca. 40 s mehr als ein Cluster auftritt. Mit diesem Wissen ist in der Folge eine differenzierte Auswertung der Situationen möglich, in denen eine verlässliche Vorhersage über den Geschwindigkeitsverlauf

schwierig ist. In diesem Fall ist z. B. mit einer weiteren Analyse zu erkennen, dass bei langsamen Anfahren bzw. einer Position hinten in der Warteschlange ein Anhalten an der nächsten LSA unvermeidlich ist.

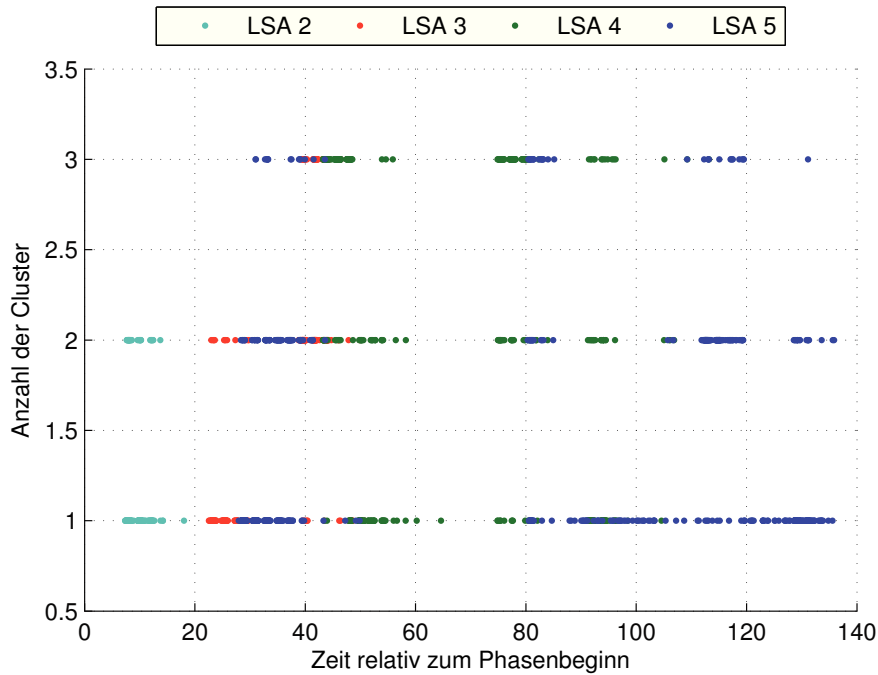


Abbildung 7.7: Einfluss der relativen Zeit zum Phasenbeginn auf die Anzahl der Cluster in Szenario 4

Im Vergleich zum Szenario 1 ist in Abbildung 7.7 die relative Zeit zum Phasenbeginn und die Anzahl der Cluster für Szenario 4 dargestellt. Dabei ist zu erkennen, dass es für jede LSA-Zeitpunkte gibt, in denen nur ein Cluster entsteht, sprich die Vorhersage des Geschwindigkeitsverlaufes eindeutig ist. In Situationen, in denen dies nicht der Fall ist, kann also über eine solche Analyse herausgefunden werden, wie die Geschwindigkeit angepasst werden müsste, um die entsprechende Eintrittswahrscheinlichkeit zu erhöhen.

7.3 Zusammenfassung und Ausblick

In diesem Kapitel wurde TLCoRA, ein Algorithmus zur ursachenorientierten Analyse von Fahrprofilen, vorgestellt, mit dem Ziel, den Geschwindigkeitsverlauf bei Überfahrt der vorausliegenden Kreuzung vorherzusagen. Um dieses Ziel zu erreichen, nutzt TLCoRA

die Korrelation zwischen LSA aufeinander folgender Kreuzungen. Dabei ist TLCorA der erste Algorithmus, welcher auf Basis der bestimmten Synchronisation mit der Phase der zurückliegenden LSA versucht, die gegebene Korrelation für eine Vorhersage zu nutzen. TLCorA vereint dabei die Möglichkeit aus Fahrprofilen anderer Fahrzeuge Rückschlüsse auf den zukünftigen Geschwindigkeitsverlauf zu ziehen und den Fakt, dass LSA zu Verkehrssteuerungszwecken korreliert bzw. koordiniert sind.

In Simulationsszenarien mit verschiedenen LSA-Steuerungen konnte die Anwendbarkeit von TLCorA auf korrelierte LSA gezeigt werden. Dazu wurden Festzeitsteuerungen, tageszeitabhängige und verkehrsadaptive Steuerungen in einer Verkehrssimulation implementiert. Die Ergebnisse zeigen, dass insbesondere in den Szenarien mit Festzeitsteuerung und tageszeitabhängiger Steuerung eine Prognose des Geschwindigkeitsverlaufs mit einer hohen Eintrittswahrscheinlichkeit durchgeführt werden konnte. Für Festzeitsteuerungen konnte fast in allen Fällen ein Geschwindigkeitsverlauf mit einer Eintrittswahrscheinlichkeit von 100 % berechnet werden. Für tageszeitabhängige Steuerungen wurde eine Eintrittswahrscheinlichkeit von 100 % noch immer in 80 % aller Fälle erreicht. Bei der verkehrsadaptiven Freigabezeitanpassung mit fester Umlaufzeit konnte die Funktionsweise von TLCorA ebenfalls gezeigt werden. Allerdings ist die Eintrittswahrscheinlichkeit des wahrscheinlichsten Geschwindigkeitsverlaufs gesunken, sodass nur noch in ca. 55 % eine eindeutige Bestimmung des Geschwindigkeitsverlaufs möglich ist. Die guten Ergebnisse und die weite Verbreitung von korrelierten LSA lassen erwarten, dass TLCorA auch in der Realität einen Beitrag zur Reduzierung des Kraftstoffverbrauchs an Kreuzungen leisten kann.

Während der Entwicklung und Analyse von TLCorA wurden diverse weitere Forschungsfragen aufgeworfen, die es in weiteren Arbeiten zu untersuchen gilt. Die Hauptaufgabe ist sicherlich, die Funktionsweise von TLCorA in der Realität zu untersuchen. Dabei müssen unterschiedliche Fragen aufgegriffen werden, z. B. nach der Varianz der Geschwindigkeitsverläufe zwischen zwei LSA oder der Genauigkeit der Synchronisation, welche durch das Anfahrverhalten der anderen Verkehrsteilnehmer beeinflusst wird.

Ein weiterer Punkt ist die Analyse der Funktionsweise von TLCorA in Situationen mit Kapazitätsengpässen an Kreuzungen. Die Vermutung ist, dass, sobald die LSA nicht mehr der wesentliche Einflussfaktor auf den Geschwindigkeitsverlauf ist, die Vorhersage des Geschwindigkeitsverlaufs nicht mehr möglich ist. Interessant ist weiterhin die Funktionsweise von TLCorA unter Einflüssen einer zentralisierten und adaptiven Verkehrssteuerung. Insbesondere moderne, modellbasierte Steuerungsverfahren sind hierbei zu untersuchen.

Abschließend ist in Bezug auf TLSE zu untersuchen, wie genau sich die beiden Algorithmen in der Realität ergänzen und wie die Ergebnisse gemeinsam in einer Fahrfunktion genutzt werden können.

Kapitel 8

Zusammenfassung und Ausblick

In dieser Arbeit wurde ein System zur Bewertung von möglichen Geschwindigkeitsprofilen auf dem vorausliegenden Streckenabschnitt auf Basis von gesammelten Fahrprofilen vorgestellt. Dabei wurden drei Algorithmen vorgestellt: Eine wirkungsorientierte Analyse und zwei ursachenorientierte Analysen (TLSE und TLCoRA). Die wirkungsorientierte Analyse erfordert keine Kenntnis über die verkehrlichen Einflussfaktoren auf den Geschwindigkeitsverlauf, wohingegen die ursachenorientierten Analysen zusätzliche Informationen über die Art des Einflusses erfordern. Der Schwerpunkt der ursachenorientierten Analysen wurde in dieser Arbeit auf die Berechnung von möglichen Geschwindigkeitsverläufen bei der Zufahrt auf Lichtsignalanlagen gelegt.

In Kapitel 2 wurden zunächst die Anwendungsgebiete von Fahrprofilen im Allgemeinen dargestellt und die Verwendung in dieser Arbeit beschrieben. Als Beispiel für die Verwendung der bewerteten Geschwindigkeitsverläufe wurden eine Anwendung zur Kraftstoffverbrauchsreduzierung und das Potenzial untersucht, mit den hier vorgestellten Ansätzen den Kraftstoffverbrauch zu reduzieren. Die dazu verwendeten Algorithmen werden in Kapitel 3 beschrieben.

In Kapitel 4 wurden die Idee, Implementierung und Evaluierung der Erkennung von charakteristischen Fahrprofilen (wirkungsorientierte Analyse) mittels DTW auf einem Streckenabschnitt und deren Nutzung zur Berechnung der Eintrittswahrscheinlichkeiten beschrieben. Dabei wurde der Prozess der Berechnung in die Schritte Datensammlung, Segmentierung und Gruppierung von Fahrprofilen und Bewertung über mehrere Segmente aufgeteilt. Daran konnte anschließend ein Potenzial zur Kraftstoffreduzierung von 8,3 % bei einem zusätzlichen Zeitbedarf auf der Strecke von 17 % ausgewiesen werden.

Die Grundlagen der LSA-Steuerung, die verwendete Simulationsumgebung und die ausgewählten Simulationsszenarien zur Validierung der ursachenorientierten Analysen wur-

den in Kapitel 5 beschrieben. Insbesondere wurde dabei auf die Auswahl und Beschreibung der Steuerungsalgorithmen eingegangen.

Kapitel 6 beschrieb den TLSE Algorithmus (ursachenorientierte Analyse) mit dem Ziel der Schätzung der LSA-Parameter auf Basis von Fahrprofilen, die als „Beobachtungen“ des LSA-Zustandes genutzt werden. Mittels der resultierenden Parameter konnte der Status der LSA zu jedem Zeitpunkt in der Zukunft berechnet werden. In der Simulationsumgebung erreichte der Algorithmus eine Genauigkeit von über 90 % für Festzeitsteuerungen und 80 % für verkehrsadaptive Steuerungen für LSA mit fester Umlaufzeit, wobei nur 5 % aller verfügbaren Fahrprofile verwendet wurden.

Die Komplexität von Steuerungsverfahren an großen Kreuzungen und Verkehrsleitsysteme zur ständigen Anpassung der LSA-Umschaltzeiten machen das Lernen der Parameter unzuverlässig, da die Schätzungen der LSA-Parameter für jede Kreuzung ständig auf Basis der „Beobachtungen“ angepasst werden müssen. Daher wurde der TLCorA Algorithmus entwickelt und in Kapitel 7 beschrieben. Dieser Algorithmus basiert auf der Annahme, dass aufeinanderfolgende LSA korreliert sind und durch zeitliche Synchronisation mit zurückliegenden LSA auf mögliche Geschwindigkeitsprofile an der nächsten LSA geschlossen werden kann. In Simulationen konnte gezeigt werden, dass in weniger als 5 % der Fälle die möglichen Geschwindigkeitsprofile falsch bewertet wurden.

Dies ist die erste Arbeit mit dem Ziel, eine Menge von Fahrprofilen auf dem vorausliegenden Streckenabschnitt nach ihrer Eintrittswahrscheinlichkeit zu berechnen, um daraus verbrauchseffiziente Manöver abzuleiten. Es wurden Algorithmen vorgestellt, welche Lösungen für den Fall von unbekanntem und bekanntem maßgebenden Einflussfaktoren liefern. Als Erste auf diesem Gebiet wurden während der Entwicklung der Algorithmen interessante Fragestellungen aufgeworfen, welche in Zukunft weiter untersucht werden sollten. Insbesondere der Aufbau von Fahrzeugflotten mit Kommunikationseinheiten würde eine breitere Evaluierung, Verbesserung und Erweiterung der vorgeschlagenen Algorithmen möglich machen. Im Folgenden diskutieren wir eine Reihe von offenen Fragestellungen.

Charakteristische Geschwindigkeitsprofile konnten mittels Dynamic Time Warping berechnet werden, allerdings wurde die Frage nach der Fahrbarkeit der daraus abgeleiteten, üblichen Geschwindigkeitsprofile im realen Verkehr noch nicht ausreichend untersucht. Zu diesem Zweck könnte die Datenbasis vergrößert und eine Nutzerstudie in einem breiten Situationsspektrum durchgeführt werden. Bei einer Nutzerstudie wäre noch die Frage des Anzeigeconzeptes zu beantworten. Dabei stellen sich z. B. folgende Fragen: Wie

kann dem Fahrer die Unsicherheit einer Information visualisiert werden? Akzeptiert ein Fahrer ein solches System?

Weiterhin stellt sich die Frage, inwieweit eine Geschwindigkeitsprognose auf Basis von Fahrprofilen durch „live“ Informationen (z. B. durch Fahrzeug-zu-Fahrzeug Kommunikation) gestützt werden kann, sodass die Anzahl der fehlerhaften Berechnungen reduziert wird. Außerdem wäre zu untersuchen, wie mit der Reaktion der Fahrer auf vorgeschlagene Manöver die Datenbasis des Systems beeinflusst wird. Ein Test des Systems über einen längeren Zeitraum zur Analyse des Einflusses wäre eine Möglichkeit, dies zu untersuchen.

Die in dieser Arbeit vorgestellte Idee, LSA-Parameter als Grundlage für die Geschwindigkeitsprognose aus Fahrprofilen zu lernen, wirft ebenfalls interessante Fragen auf. Zum einen wären die vorgeschlagenen Algorithmen im realen Straßenverkehr zu untersuchen, um die Genauigkeit der Schätzung der LSA-Parameter einzelner Fahrtrichtungen festzustellen. Anschließend könnten die vorgeschlagenen Algorithmen an Kreuzungen unterschiedlichster Geometrie mit dem Ziel untersucht werden, den Algorithmus zur Kombination der fahrtrichtungsspezifischen LSA-Parameter zu analysieren und bei Bedarf zu verbessern.

Zum anderen wurden interessante algorithmische Fragestellungen identifiziert. Bei tageszeitabhängigen Steuerungen können z. B. ausgewählte Messungen anderer Tage zur Schätzung der LSA-Parameter verwendet werden. Dazu ist jedoch eine Analyse der geschätzten LSA-Parameter über einem Tag notwendig. Weiterhin ist zu untersuchen, welchen Einfluss mehrfaches Anhalten vor und im Kreuzungsbereich der Fahrzeuge auf den Algorithmus hat.

Bei der Kombination von TLCorA und TLSE zu einem System stellen sich gleich mehrere Fragen: In welcher Situation wird TLCorA respektive TLSE verwendet? Muss diese Entscheidung einmalig für bestimmte Straßenabschnitte oder vielleicht in Abhängigkeit der Tageszeit oder des Verkehrsflusses getroffen werden? Die Fragen sind bei der Umsetzung der beiden Algorithmen mit realen Fahrprofilen zu untersuchen.

Zusammenfassend wurde in dieser Arbeit gezeigt, dass die Bewertung von Geschwindigkeitsprofilen für die vorausliegende Strecke auf Basis von Fahrprofilen möglich ist und daraus verbrauchseffiziente Fahrmanöver abgeleitet werden können. Diese Bewertung wurde im Allgemeinen durch eine wirkungsorientierte Analyse durchgeführt. Im Speziellen wurde eine ursachenorientierte Analyse zur Prognose des Status der vorausliegenden LSA bei Ankunft durchgeführt. Neben der Berechnung von verbrauchseffizienten

Fahrmanövern sind diverse andere Anwendungen auf Basis dieser Informationen, z. B. verbesserte Reisezeitschätzungen, effiziente Routenwahl oder Restrotanzeige, vorstellbar.

Literaturverzeichnis

Eigene Publikationen

- [KKKM11] Markus Koegel, Wolfgang Kiess, Markus Kerper, and Martin Mauve. Compact Vehicular Trajectory Encoding. In *VTC 2011 Spring: Proceedings of the 73th IEEE Vehicular Technology Conference*, May 2011.
- [KKM09] Markus Kerper, Wolfgang Kiess, and Martin Mauve. Coordinated VANET Experiments - a Methodology and First Results. In *VANET 2009: Proceedings of the Sixth ACM International Workshop on Vehicular Inter-Networking*, pages 109–116, September 2009.
- [KWM12] Markus Kerper, Christian Wewetzer, and Martin Mauve. Analyzing Vehicle Traces to Find and Exploit Correlated Traffic Lights for Efficient Driving. In *IV '12: Proceedings of the IEEE Intelligent Vehicles Symposium*, June 2012.
- [KWSM12] Markus Kerper, Christian Wewetzer, Andreas Sasse, and Martin Mauve. Learning traffic light phase schedules from velocity profiles in the cloud. In *NTMS - Mobility and Wireless Networks Track (NTMS'2012 - Mobility & Wireless Networks Track)*, Istanbul, Turkey, May 2012.
- [KWT⁺11] Markus Kerper, Christian Wewetzer, Holger Trompeter, Wolfgang Kiess, and Martin Mauve. Driving More Efficiently - The Use of Inter-Vehicle Communication to Predict a Future Velocity Profile. In *VTC 2011 Spring: Proceedings of the 73th IEEE Vehicular Technology Conference*, May 2011.

Patente

- [KW12] Markus Kerper and Christian Wewetzer. Verfahren und Vorrichtung zum Bereitstellen einer Fahrempfehlung für einen Streckenabschnitt. In *Deutsche Patentanmeldung Nr. 10 2010 054 077.3*, Juni 2012.
- [SKHL13] Andreas Sasse, Markus Kerper, Georg Happich, and Thorsten Lang. Übertragung fahrzeugrelevanter Daten mittels Car2Car. In *Deutsche Patentanmeldung Nr. 10 2011 115 421 A1*, April 2013.
-

Andere Referenzen

- [App08] Christian Appelt. Entwicklung eines Fahrzeugmodells zur vielfachechtzeitfähigen Kraftstoffverbrauchssimulation. In *Technische Universität zu Berlin, Diplomarbeit*, 2008.
- [Bar10] Patrick Bartsch. *Fahrtoptimierung im Energiemanagement-Kontext - Verbrauchsoptimierte Routen für Kraftfahrzeuge*. PhD thesis, Gottfried Wilhelm Leibniz Universität Hannover, 2010.
- [BC94] D. J. Berndt and J. Clifford. Using dynamic time warping to find patterns in time series, April 1994.
- [BEJS05] R. Bruntrup, S. Edelkamp, S. Jabbar, and B. Scholz. Incremental map generation with gps traces. In *Intelligent Transportation Systems, 2005. Proceedings. 2005 IEEE*, pages 574–579. IEEE, 2005.
- [BG07] H. Bar Gera. Evaluation of a cellular phone-based system for measurements of traffic speeds and travel times: A case study from Israel. *Transportation Research Part C*, 15(6):380–391, December 2007.
- [BKM⁺09] Dr.-Ing. R. Braun, Dr.-Ing. C. Kemper, C. Menig, Prof. Dr.-Ing. F. Busch, Dr. R. Hildebrandt, I. Paulus, R. Preßlein-Lehle, and F. Weichenmeier. Travolution - Netzweite Optimierung der Lichtsignalsteuerung und LSA-Fahrzeug-Kommunikation, März 2009.
- [CK09] Lili Cao and John Krumm. From gps traces to a routable road map. In *Proceedings of the 17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, GIS '09*, pages 3–12, New York, NY, USA, 2009. ACM.

- [CK10] Yihua Chen and John Krumm. Probabilistic modeling of traffic lanes from gps traces. In *Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems, GIS '10*, pages 81–88, New York, NY, USA, 2010. ACM.
- [DE84] William H. Day and Herbert Edelsbrunner. Efficient algorithms for agglomerative hierarchical clustering methods. *Journal of Classification*, 1(1):7–24, December 1984.
- [DGM97] Gautam Das, Dimitrios Gunopulos, and Heikki Mannila. Finding similar time series. In *PKDD '97: Proceedings of the First European Symposium on Principles of Data Mining and Knowledge Discovery*, pages 88–100, London, UK, 1997. Springer-Verlag.
- [DJTZ11] Bernd Dornieden, Lutz Junge, Philipp Themann, and Adrian Zlocki. Analysis of an energy efficient longitudinal vehicle control based on measurements of driving situations. In *20th Aachen Colloquium Automobile and Engine Technology*, 2011.
- [ES03] Stefan Edelkamp and Stefan Schrödl. Route planning and map inference with global positioning traces. In Rolf Klein, Hans-Werner Six, and Lutz Wegner, editors, *Computer Science in Perspective*, pages 128–151, New York, NY, USA, 2003. Springer-Verlag New York, Inc.
- [FK10] Alireza Fathi and John Krumm. Detecting road intersections from gps traces. In *Proceedings of the 6th international conference on Geographic information science, GIScience'10*, pages 56–69, Berlin, Heidelberg, 2010. Springer-Verlag.
- [Fri09] Prof. Dr.-Ing. Markus Friedrich. Das Projekt AMONES. In *AMONES-Symposium*, November 2009.
- [fSuV10] Forschungsgesellschaft fuer Straßen-und Verkehrswesen. RiLSA - Richtlinien für Lichtsignalanlagen, 2010.
- [Goo] Inc. Google. Google earth. Stand: 18.03.2010.
- [GToO⁺05] R.L. Gordon, W. Tighe, United States. Federal Highway Administration. Office of Operations, Dunn Engineering Associates, and ITS Siemens. *Traffic control systems handbook*. US Department of Transportation, Federal Highway Administration, Office of Operations, 2005.
- [HB01] J. Hightower and G. Borriello. Location systems for ubiquitous computing. *Computer*, 34(8):57–66, aug 2001.
- [HB03] Stefan Hinz and Albert Baumgartner. Automatic extraction of urban road networks from multi-view aerial imagery. In *ISPRS Journal of Photogrammetry and Remote Sensing*, pages 83–98, 2003.

- [HFN06] Erik Hellström, Anders Fröberg, and Lars Nielsen. A real-time fuel-optimal cruise controller for heavy trucks using road topography information. In *SAE Technical Paper 2006-01-0008*, SAE World Congress, Detroit, MI, USA, 2006.
- [HLO99] W. Huber, M. Lüdke, and Rainer Ogger. Extended floating-car data for the acquisition of traffic information. In *Proceedings of the 6th World Congress on Intelligent Transport Systems*, pages 1–9, 1999.
- [HPaP08] W. Hongsakham, W. Pattara-atikom, and R. Peachavanish. Estimating road traffic congestion from cellular handoff information using cell-based neural networks and k-means clustering. In *Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 2008. ECTI-CON 2008. 5th International Conference on*, volume 1, pages 13 – 16, may 2008.
- [HWH⁺10] J. Herrera, D. Work, R. Herring, X. Ban, Q. Jacobson, and A. Bayen. Evaluation of traffic data obtained via GPS-enabled mobile phones: The Mobile Century field experiment. *Transportation Research Part C*, 18(4):568–583, August 2010.
- [Int09] TomTom International. OpenLR. An open standard for encoding, transmitting and decoding location references in digital maps. Technical report, International, TomTom, 2009.
- [KBH⁺] N. Kohut, F. Borrelli, K. Hedrick, A. Lamprecht, J. Lee, C. H. Lee, and D. Rosario. Utilization of intelligent transport systems information to increase fuel economy through engine control.
- [KBMS11] Markus Koegel, Daniel Baselt, Martin Mauve, and Björn Scheuermann. A Comparison of Vehicular Trajectory Encoding Techniques. In *MedHoc-Net '11: Proceedings of the 10th Annual Mediterranean Ad Hoc Networking Workshop*, pages 87–94, June 2011.
- [KDH⁺05] B.S. Kerner, C. Demir, R.G. Herrtwich, S.L. Klenov, H. Rehborn, M. Alek-sic, and A. Haug. Traffic state detection with floating car data in road networks. In *IEEE Intelligent Transportation Systems (ITS)*, 2005.
- [Keo02] E. Keogh. Exact indexing of dynamic time warping, 2002.
- [KHRW02] Daniel Krajzewicz, Georg Hertkorn, Christian Rössel, and Peter Wagner. SUMO (simulation of urban mobility) — an open-source traffic simulation. In Marwan Al-Akaidi, editor, *MESM 2002, 4th Middle East Symposium on Simulation and Modelling*, pages 183–187, Erlangen, Germany, October 2002. SCS European Publishing House.
- [KM11] Markus Koegel and Martin Mauve. On the Spatio-Temporal Information Content and Arithmetic Coding of Discrete Trajectories. In *MobiQuitous '11: Proceedings of the 8th Annual International Conference on Mobile*

- and Ubiquitous Systems: Computing, Networking and Services*, December 2011.
- [KPKT10] Florian Kranke, Holger Poppe, Arne Kesting, and Martin Treiber. Der baustellenlotse - ein stauvermeidendes fahrerassistenzsystem auf grundlage von fahrzeugsensordaten und fahrzeug-infrastruktur-kommunikation. *Straßenverkehrstechnik*, 1:12–19, 2010.
- [KPM11] Emmanouil Koukoumidis, Li-Shiuan Peh, and Margaret Rose Martonosi. Signalguru: leveraging mobile phones for collaborative traffic signal schedule advisory. In *Proceedings of the 9th international conference on Mobile systems, applications, and services*, MobiSys '11, pages 127–140, New York, NY, USA, 2011. ACM.
- [Kör08] Matthias Körner. Taxi floating car daten für dresden. Technical report, Forschungsgesellschaft für Straßen- und Verkehrswesen, 2008.
- [KRPK11] B.S. Kerner, H. Rehborn, J. Palmer, and S.L. Klenov. Using Probe Vehicle Data to Generate Jam Warning Messages. In *Traffic Engineering and Control*, pages 141–148, 2011.
- [Leh11] Bernd Lehmann. Bestimmung des maximalen kraftschlussbeiwertes mittels wetter-, fahrzeug- und kartendaten, Dezember 2011.
- [MNDN11] T. Marita, M. Negru, R. Danescu, and S. Nedevschi. Stop-line detection and localization method for intersection scenarios. In *Intelligent Computer Communication and Processing (ICCP), 2011 IEEE International Conference on*, pages 293 –298, aug. 2011.
- [MP99] Mario E. Munich and Pietro Perona. Continuous dynamic time warping for translation-invariant curve alignment with applications to signature verification. In *In Proceedings of 7 th International Conference on Computer Vision*, pages 108–115, 1999.
- [Nie] Lars Nielsen. Look-ahead control for heavy trucks to minimize trip time and fuel consumption.
- [Oer09] Robert Oertel. Optimierung des verkehrsablaufs an lichtsignalanlagen auf grundlage von floating-car-datensätzen und daten aus der fahrzeug-infrastruktur-kommunikation. *Studienarbeit an der Technischen Universität Dresden an der Fakultät Verkehrswissenschaften Friedrich List am Institut für Verkehrstelematik*, February 2009.
- [PKS09] Holger Poppe, Florian Kranke, and Torsten Scheurer. Dynamische generierung von strecken- und verkehrszustandsattributen für fahrerassistenzsysteme mit car-to-x-kommunikation. In *AAET 2009 - Automatisierungs-, Assistenzsysteme und eingebettete Systeme für Transportmittel*, Braunschweig, Germany, 2009. ITS Niedersachsen e.V.

- [Pri10] C. Priemer. *Kommunikationsdatenbasierte, dezentrale Lichtsignalsteuerung in städtischen Netzen*. Shaker, 2010.
- [Reg10] Region Nürnberg im Rahmen des Forschungsbereichs "Verkehrsmanagement 2010" des Bundesministeriums für Bildung und Forschung. Operative regionale integrierte und optimierte korridorsteuerung (orinoko). [http://http://www.orinoko.info/](http://www.orinoko.info/), 2010.
- [RIT] RITA (Research And Innovative Technology Administration). Intelligent transportation systems deployment statistics for operational strategies. <http://www.itsdeployment.its.dot.gov/am.aspx>.
- [SC07a] S. Salvador and P. Chan. Fastdtw: Toward accurate dynamic time warping in linear time and space, 2007.
- [SC07b] Stan Salvador and Philip Chan. Toward accurate dynamic time warping in linear time and space. *Intell. Data Anal.*, 11(5):561–580, 2007.
- [Sch09] Ralf-Peter Schäfer. Iq routes and hd traffic: technology insights about tomtom's time-dynamic navigation concept. In *Proceedings of the 7th joint meeting of the European software engineering conference and the ACM SIGSOFT symposium on The foundations of software engineering, ESEC/FSE '09*, pages 171–172, New York, NY, USA, 2009. ACM.
- [SG10] Karl-Peter Jäker Sandra Gausemeier, Ansgar Trächtler. Multi-Objective Optimization of a Vehicle Velocity Profile by Means of Dynamic Programming. In *6th IFAC Symposium Advances in Automotive Control*, July 2010.
- [SH09] I. Skog and P. Handel. In-car positioning and navigation technologies - a survey. *Intelligent Transportation Systems, IEEE Transactions on*, 10(1):4–21, march 2009.
- [STBW02] Ralf-Peter Schäfer, Kai-Uwe Thiessenhusen, Elmar Brockfeld, and Peter Wagner. A traffic information system by means of real-time floating-car data. In *ITS World Congress 2002*, 2002. LIDO-Berichtsjahr=2003.
- [STK05] A.H. Sayed, A. Tarighat, and N. Khajehnouri. Network-based wireless location: challenges faced in developing techniques for accurate wireless location information. *Signal Processing Magazine, IEEE*, 22(4):24 – 40, july 2005.
- [SWR⁺04] Stefan Schroedl, Kiri Wagstaff, Seth Rogers, Pat Langley, and Christopher Wilson. Mining gps traces for map refinement. *Data Min. Knowl. Discov.*, 9(1):59–87, July 2004.
- [Tro10] Holger Trompeter. Berechnung eines zukünftigen Geschwindigkeitsprofils basierend auf Fahrzeug-zu-Fahrzeug Kommunikation. In *Heinrich-Heine-Universität Düsseldorf, Masterarbeit*, 2010.

- [Tur00] S. Turksma. The various uses of floating car data. In *Road Transport Information and Control, 2000. Tenth International Conference on (Conf. Publ. No. 472)*, pages 51–55, 2000.
- [ubAa] u-blox AG. Lea-5, neo-5, tim-5h u-blox 5 gps modules - hardware integration manual. Stand: 10.05.2010.
- [ubAb] u-blox AG. Neo-6 datasheet. Stand: 03.10.2012.
- [VHGK03] Michail Vlachos, Marios Hadjieleftheriou, Dimitrios Gunopulos, and Eamonn Keogh. Indexing multi-dimensional time-series with support for multiple distance measures. In *Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining, KDD '03*, pages 216–225, New York, NY, USA, 2003. ACM.
- [WHWL08] Axel Wegener, Horst Hellbrück, Christian Wewetzer, and Andreas Luebke. VANET Simulation Environment with Feedback Loop and its Application to Traffic Light Assistance. In *AutoNet 2008: Proceedings of the 3rd IEEE Workshop on Automotive Networking and Applications*, December 2008.
- [WLL96] Marcel Westerman, Remco Litjens, and Jean-paul Linnartz. Integration of probe vehicle and induction loop data: Estimation of travel times and automatic incident detection. Institute of transportation studies, research reports, working papers, proceedings, Institute of Transportation Studies, UC Berkeley, 1996.
- [WPR⁺08] Axel Wegener, Michał Piórkowski, Maxim Raya, Horst Hellbrück, Stefan Fischer, and Jean-Pierre Hubaux. TraCI: an interface for coupling road traffic and network simulators. In *Proceedings of the 11th communications and networking simulation symposium, CNS '08*, pages 155–163, New York, NY, USA, 2008. ACM.
- [ZHT06] Zhang Zhang, Kaiqi Huang, and Tieniu Tan. Comparison of similarity measures for trajectory clustering in outdoor surveillance scenes. *18th International Conference on Pattern Recognition (2006)*, 3(c):1135–1138, 2006.

Die hier vorgelegte Dissertation habe ich eigenständig und ohne unerlaubte Hilfe angefertigt. Die Dissertation wurde in der vorgelegten oder in ähnlicher Form noch bei keiner anderen Institution eingereicht. Ich habe bisher keine erfolglosen Promotionsversuche unternommen.

Braunschweig, den 21.05.2013

Markus Kerper