
Schaltzeitprädiktion und Routenoptimierung für die Ampelassistentz in Smart Cities

Valentin Protschky

Dissertation
an der Fakultät für Mathematik, Informatik und Statistik
der Ludwig-Maximilians-Universität München

vorgelegt von
Valentin Protschky

Tag der Einreichung: 10. Mai 2016

Schaltzeitprädiktion und Routenoptimierung für die Ampelassistentz in Smart Cities

Valentin Protschky

Dissertation
an der Fakultät für Mathematik, Informatik und Statistik
der Ludwig-Maximilians-Universität München

vorgelegt von
Valentin Protschky

| | |
|----------------------|---|
| 1. Berichterstatter: | Prof. Dr. Claudia Linnhoff-Popien, LMU München |
| 2. Berichterstatter: | Prof. Dr. Stefan Fischer, Universität zu Lübeck |
| Tag der Einreichung: | 10. Mai 2016 |
| Tag der Disputation: | 18. November 2016 |

Eidesstattliche Versicherung

(siehe Promotionsordnung vom 12. Juli 2011 in der Fassung der 1. Änderungssatzung vom 6. Juni 2012, § 8, Abs. 2 Pkt. 5)

Hiermit erkläre ich an Eides statt, dass die Dissertation von mir selbstständig, ohne unerlaubte Beihilfe angefertigt ist.

Valentin Protschky

Zusammenfassung

Die zunehmende Digitalisierung und Vernetzung bietet im Automobilbereich und in urbanen Räumen Chancen für neue Assistenzfunktionen, die zu einem sicheren, komfortableren und effizienteren Fahren führen können. Das Potential durch die Nutzung gesammelter Daten ist enorm - so können Gefahren frühzeitig erkannt, Staus noch präziser vorhergesagt, oder die CO₂-Emission reduziert werden. Insbesondere in urbanen Räumen ist die Lichtsignalanlage in ihrer Aufgabe der Steuerung von Verkehrsströmen hauptverantwortlich für viele Staus und Unfälle, aber auch für erhöhten Schadstoffausstoß wieder beschleunigender Fahrzeuge. Mit dem Wissen über die zukünftigen Signalzustände einer Lichtsignalanlage können diese negativen Nebeneffekte abgemildert werden. So kann mithilfe einer Grünband-Geschwindigkeitsempfehlung die Fahrzeuggeschwindigkeit so angepasst werden, dass ein Stopp vermieden wird. Eine Rotlicht-Überfahrenswarnung kann unterstützen, Unfälle zu vermeiden, indem vor bevorstehenden Rotlichtverstößen gewarnt wird. Eine ampeladaptive Route kann wiederum Staus an roten Ampeln reduzieren.

In der vorliegenden Arbeit werden neue Konzepte zur Prognose zukünftiger Signalzustände an koordinierten Knotenpunkten in Städten mithilfe von crowdsourcing-Daten erforscht. Einerseits wird hierzu der Aspekt einer vernetzten Schaltzeitprognose mittels Kommunikation zwischen Fahrzeugen und der Verkehrsinfrastruktur untersucht. Dazu wird ein Verfahren zur großflächigen Schaltzeitprognose in urbanen Räumen mithilfe vergangener Schaltzeitinformationen entwickelt. Die zentrale Herausforderung stellt hierbei, neben der Akquise von Daten, die Verkehrsabhängigkeit vieler Lichtsignalanlagen. Das entwickelte Verfahren wird anhand der Referenzstadt München implementiert und evaluiert. Darüber hinaus wird ein Verfahren zur Schätzung zukünftiger Signalzustände mithilfe von Daten aus dem Fahrzeugumfeld entwickelt. Entgegen des ersteren Ansatzes werden nicht mehr Verkehrszentralen als Datenquelle herangezogen, sondern gesammelte Daten aus dem Fahrzeug verwendet. Konkret wird die Floating Car Data Technologie auf die Nutzbarkeit zur Rekonstruktion und Schätzung von Schaltzeiten untersucht. Hierbei wird neben einer Potentialabschätzung der Technologie für dieses Einsatzszenario ein Modell zur Extraktion von Schaltzeitinformationen mittels gängiger Machine-Learning Methoden vorgestellt.

Ein weiterer Forschungsschwerpunkt der vorliegenden Arbeit liegt auf der Konzeption eines dynamischen Routingverfahrens, welches die zukünftigen Schaltzeiten im Verkehrsnetz in die Routenwahl einbezieht. Ziel dieses am-

peladaptiven Routingverfahrens ist es, die Wartezeit an Ampeln aufgrund von Rotzeiten zu minimieren und so die Reisezeit zu verkürzen. Hierzu müssen zunächst Verfahren entwickelt werden, um Unzulänglichkeiten in der bestehenden Graphstruktur in Navigationskarten effizient zu beheben, so dass Informationen über zukünftige Signalzustände an Knotenpunkten korrekt berücksichtigt werden können. Ferner wird eine Bewertung der tatsächlichen Reisezeitersparnis im realistischen Umfeld durchgeführt. Hierzu wird für ein Testfeld in München der Größe 100 km² eine simulative Untersuchung des zu erwartenden Reisezeitgewinnes des ampeladaptiven Routingverfahrens im Vergleich zum klassischen Routingverfahren durchgeführt.

Abstract

The increasing digitization provides opportunities regarding new assisting functionalities for both for the automotive sector and for urban regions, leading to a safer, more comfortable and more efficient driving. The benefits of using collected data are enormous - risk can be detected in good time, jams be predicted more accurately and CO₂-emission be reduced. Especially in urban regions, traffic lights, in their task of managing traffic, are one of the main causes for jams and accidents, yet also for increased exhaust emissions by accelerating vehicles. With the knowledge of traffic lights' future signal states, these negative side-effects could be softened. Thus, vehicle velocities can be adapted by green light optimal speed advisory so as to avoid a complete stop at a traffic light, a red light violation advisory may help avoiding accidents and traffic light adaptive routing can help reducing jams at crossings.

In this thesis new concepts for predicting future signal states at signalized crossings in cities based on crowdsourcing-data are the scope of research. On the one hand, the aspect of a connected signal time prediction through communication between vehicles and traffic management institutions is examined. For this purpose, a concept for extensive signal time prediction with historical data is developed. The central challenge, besides the acquisition of data, is the fact that many traffic lights are traffic adaptive. The proposed concept is implemented and evaluated for the city of Munich.

Furthermore, a procedure for the estimation of future signal states based on data from the vehicle environment is developed. In opposition to the first approach, where data from public authorities has been used, data collected by vehicles build the database. More precisely, the Floating Car Data Technology is examined for its usability to reconstruct and estimate signal times of traffic lights. At this, both an assessment of the potential of this technology for the use-case and a procedure for the extraction of signal time information by means of current machine learning methods is proposed.

Another focus of research of this thesis is the conception of a dynamic routing strategy taking into account future signal times in a traffic network. The aim of this so-called traffic-adaptive routing strategy is to reduce waiting times at traffic lights due to red phases and in consequence, to minimize the traveling time. To this, a method is developed so as to eliminate inadequacies of the underlying graph structure in navigation maps. This is necessary for a proper consideration of future signal states at signalized crossings. Moreover, an evaluation of the probable traveling time gain under realistic conditions is

conducted. For that, a test field of 100 km² in Munich is chosen to estimate the expected traveling time gain of a traffic adaptive routing strategy over a standard routing strategy.

Inhaltsverzeichnis

| | | |
|----------|---|-----------|
| 1 | Einführung | 1 |
| 1.1 | Vision Smart City: Städteseitige Treiber der Ampelassistentz | 2 |
| 1.2 | Vernetztes Fahrzeug: Fahrzeugseitige Treiber der Ampelassistentz | 3 |
| 1.3 | Aufgabenstellung und Ziel der Arbeit | 4 |
| 1.4 | Vorgehensmodell und Struktur der Arbeit | 5 |
| 1.5 | Vorveröffentlichungen | 5 |
| 2 | Grundlagen der Ampelassistentz | 9 |
| 2.1 | Übersicht über Assistenzfunktionen | 9 |
| 2.1.1 | Allgemeine Assistenzfunktionen | 9 |
| 2.1.2 | Ampelassistentzfunktionen | 10 |
| 2.2 | Projekte zum Verkehr der Zukunft | 13 |
| 2.2.1 | MDM | 14 |
| 2.2.2 | UR:BAN | 14 |
| 2.2.3 | Frühere Forschungsprojekte | 15 |
| 2.3 | Verkehrssteuerung | 16 |
| 2.3.1 | Fachbegriffe von Lichtsignalanlagen | 16 |
| 2.3.2 | Steuerungsstrategien für Lichtsignalanlagen | 17 |
| 2.3.3 | Steuerungsverfahren für Lichtsignalanlagen | 19 |
| 2.3.4 | Potentiale für Ampelassistentzfunktionen in Europa und den USA | 23 |
| 2.4 | Floating Car Data | 26 |
| 2.4.1 | Begriffliche Abgrenzung und Aufbau | 26 |
| 2.4.2 | Charakteristika von Floating Car Data | 27 |
| 2.4.3 | Potential und Risiken von (X)FCD | 30 |
| 2.5 | Straßennetze als Graphen | 30 |
| 2.5.1 | Routingverfahren in Straßennetzen | 31 |
| 2.5.2 | Basisalgorithmen für Routingverfahren | 31 |
| 2.5.3 | Routenplanung in Straßennetzen | 32 |
| 3 | Lernen von Signalzuständen mit historischen Daten | 35 |
| 3.1 | Vorveröffentlichungen | 35 |
| 3.2 | Verfahren zur Schaltzeitprognose mit Schaltinformationen | 36 |
| 3.3 | Anforderungen an eine Prognose | 37 |
| 3.4 | Bestehende Ansätze zur Schaltzeitprognose mit Schaltinformationen | 39 |
| 3.4.1 | Ansätze aus verwandten Arbeiten | 40 |
| 3.4.2 | Beiträge aus Vorarbeiten: Kalman Filter Ansatz | 41 |

| | | |
|----------|--|------------|
| 3.5 | Rückkopplungssystem zur Schaltzeitprognose | 42 |
| 3.5.1 | Datengrundlage für die Schaltzeitprognose | 42 |
| 3.5.2 | Funktionsbeschreibung des Rückkopplungssystems | 44 |
| 3.6 | Vergleichende Bewertung des Rückkopplungssystems | 48 |
| 3.6.1 | Gegenübergestellte Prognoseverfahren im Überblick | 48 |
| 3.6.2 | Ergebnisse der vergleichenden Bewertung | 50 |
| 3.6.3 | Folgerung | 54 |
| 3.7 | Zusammenfassung | 54 |
| 4 | Lernen von Signalzuständen mit Floating Car Data | 59 |
| 4.1 | Vorveröffentlichungen | 60 |
| 4.2 | FCD-basierte Ansätze in Kreuzungsbereichen | 60 |
| 4.2.1 | Verfahren zur Verkehrsflussanalyse an Kreuzungen | 60 |
| 4.2.2 | Verfahren zum Lernen von Signalzuständen | 62 |
| 4.3 | Beiträge zur FCD-basierten Signalzustandsschätzung | 65 |
| 4.3.1 | Theoretische Betrachtung der FCD-basierten Signalzustandsschätzung | 65 |
| 4.3.2 | Bewertung der theoretischen Betrachtung | 74 |
| 4.3.3 | FCD-basierte Signalzustandsschätzung im Realumfeld: Lernen der Umlaufzeit | 76 |
| 4.3.4 | Vergleichende Bewertung des Verfahrens zum Lernen der Umlaufzeit | 97 |
| 4.3.5 | FCD-basierte Signalzustandsschätzung im Realumfeld: Lernen von Schaltzeitpunkten | 105 |
| 4.3.6 | Bewertung des Verfahrens zum Lernen von Schaltzeitpunkten | 107 |
| 4.4 | Zusammenfassung | 109 |
| 5 | Ampeladaptives Routing | 113 |
| 5.1 | Vorveröffentlichungen | 114 |
| 5.2 | Voraussetzungen für das ampeladaptive Routing | 114 |
| 5.2.1 | Verfügbarkeit eines Kommunikationskanals | 114 |
| 5.2.2 | Verfügbarkeit von Schaltzeitprognosen | 115 |
| 5.2.3 | Verfügbarkeit von Verkehrsinformationen | 115 |
| 5.2.4 | Eindeutigkeit der Zuordnung von Kanten des Routinggraphen zur Signalgruppe einer Lichtsignalanlage | 116 |
| 5.3 | Ansätze zur Routenoptimierung | 117 |
| 5.3.1 | Modelle zur optimalen Geschwindigkeitplanung | 118 |
| 5.3.2 | Modelle zur optimalen Routenwahl | 119 |
| 5.4 | Konzeption eines ampeladaptiven Routingverfahrens | 120 |
| 5.4.1 | Implementierung des A*-Algorithmus | 120 |
| 5.4.2 | Lokale und temporäre Knotenduplikation | 121 |
| 5.4.3 | Auswirkungen auf die Berechnungszeit | 124 |
| 5.4.4 | Modifikation der A*-Suche nach Knotenduplikation | 124 |
| 5.4.5 | Routingstrategie | 124 |
| 5.5 | Vergleichende Bewertung | 125 |

| | | |
|----------|--|------------|
| 5.5.1 | Testfeld | 125 |
| 5.5.2 | Unbekannte Signalzustände und Signalprognosen | 125 |
| 5.5.3 | Ungenauigkeit von Echtzeitverkehrsinformationen. | 131 |
| 5.6 | Zusammenfassung | 138 |
| 6 | Zusammenfassung und Ausblick | 141 |
| 6.1 | Zusammenfassung und wissenschaftlicher Beitrag | 141 |
| 6.2 | Ausblick | 143 |
| | Literaturverzeichnis | 145 |
| | Eigene Veröffentlichungen | 154 |

Danksagung

Diese Arbeit ist während meiner Zeit als externer Mitarbeiter am Lehrstuhl für Mobile und Verteilte Systeme des Instituts für Mathematik, Informatik und Statistik an der Ludwig-Maximilians-Universität München entstanden. In dieser Zeit habe ich in unterschiedlichster Form Unterstützung und Motivation von verschiedenen Personen erhalten, denen ich an dieser Stelle danken möchte.

Einen ganz besonderen Dank möchte ich zunächst an Frau Prof. Dr. Claudia Linnhoff-Popien richten, die mich während der Betreuung der vorliegenden Dissertation stets unterstützt hat. Ich möchte ihr ganz herzlich für die lehrreichen und motivierenden Diskussionen danken, die mir halfen, in der Arbeit kontinuierlich voranzuschreiten. Dank gebührt auch Herrn Prof. Dr. Stefan Fischer, der sich bereit erklärt hat, meine Arbeit als Zweitgutachter zu betreuen und Herrn Prof. Dr. Hans-Jürgen Ohlbach, der den Vorsitz meiner Prüfungskommission übernommen hat. Weiterhin bedanke ich mich ganz herzlich bei Herrn Stefan Feit, meinem Betreuer seitens der BMW Group, der immer ein offenes Ohr für mich hatte und mit mir unzählige Male sowohl inhaltliche, als auch grundsätzliche Themen meiner Promotion, neue Ideen, verworfene und wieder aufgegriffene Ansätze, diskutiert hat und dabei stets, auch bei Rückschlägen und Problemen, motivierende Worte fand. Bedanken möchte ich mich auch bei allen Kollegen am Lehrstuhl für Mobile und Verteilte Systeme für die vielen anregenden Diskussionen und Gespräche bedanken. Ein besonderer Dank gilt an dieser Stelle Dr. Kevin Wiesner, Dr. Martin Werner und Sebastian Feld. Weiter möchte ich mich für die Ermöglichung der realen Umsetzung meiner Ideen bei den Mitarbeitern der BMW-Group und des Kreisverwaltungsreferats München, Abteilung 1 - Verkehrsmanagement, bedanken. Namentlich erwähnen möchte ich an dieser Stelle Dr. Richard Wisbrun, Dr. Daniel Kotzor, Dr. Heidrun Belzner, Christian Ruhhammer, Martin Keil, Ralf Träger, Christoph Englmann und Klaus Träger.

Ein ganz besonderer Dank gilt meiner Familie, die mich stets mit Verständnis und Liebe unterstützt und nie am erfolgreichen Abschluss meiner Promotion gezweifelt hat.

1 Einführung

Die Automobilbranche befindet sich derzeit im Wandel. Neue Technologien und Innovationen entstehen vermehrt im Bereich der Fahrzeugvernetzung, die ein Enabler für intelligente Informations-, Entertainment- und Serviceangebote ist. Fahrzeuge agieren mehr und mehr als mobile Sensoren, die laufend eine Vielfalt an Daten aus dem Fahrzeugumfeld sammeln können. Der Nutzen aus den aggregierten Daten der Fahrzeuge ist enorm: So können Gefahrenwarnungen ausgegeben werden, Staus und Verkehrsaufkommen noch präziser angegeben werden, aber auch Ampelphasen gelernt und antizipiert werden. Die aktuell hohe Relevanz der digitalen Revolution in Fahrzeugen wird unterstrichen durch den Kauf von Nokia HERE durch die BMW-Group, Audi und Daimler, der im ersten Quartal 2016 abgeschlossen sein soll. Das erklärte Ziel ist, mit einem hochgenauen und laufend aktuellen Kartenmaterial eben genannte Dienste zu verbessern bzw. überhaupt zu ermöglichen und so weitere Schritte in die Richtung des automatisierten Fahrens einzuleiten. Der Vorstandsvorsitzende der BMW-Group, Harald Krüger, kommentierte den Kauf folgendermaßen: „HERE wird eine Schlüsselrolle bei der digitalen Revolution der Mobilität spielen und dabei hochpräzise Karten mit Daten aus dem Fahrzeugumfeld kombinieren, um das Fahren für alle sicherer und einfacher zu machen“ [1]. Der gemeinsame Kartendienst soll also die Grundlage für eine neue Generation von Mobilität und ortsbezogene Dienste bilden. Durch die Verknüpfung von gemeinsam gesammelten Rohdaten aus dem Fahrzeugumfeld mit dem neuen, präziseren Kartenmaterial wird der Weg geebnet für die Serienreife von Forschungsfeldern, die bereits jetzt betrieben werden. Das in dieser Arbeit beschriebene Forschungsfeld der *Schaltzeitprädiktion und Routenoptimierung für die Ampelassistenz in Smart Cities* gilt als einer von vielen Treibern für den Kauf von HERE durch die drei Automobilhersteller. So wird in der offiziellen Pressemitteilung zum Kauf von HERE der Use-Case Ampelassistenz explizit als Fallbeispiel aufgeführt: „Denkbar ist auch das Antizipieren von Ampelphasen, um ein Fahrzeug mit angepasster Motorleistung und minimiertem Verbrauch auf einer „grünen Welle“ durch die Straßen zu navigieren“ [1].

Das Forschungsfeld der Ampelassistenz wird jedoch nicht nur durch die Automobilindustrie befeuert. Auch städteseitig wird der Ruf nach intelligenten und mit der Verkehrsinfrastruktur vernetzten Fahrzeugen laut. Faktoren wie zunehmende Urbanisierung, wachsende CO₂-Belastung und begrenzte Ausbaumöglichkeiten führen zur Suche nach innovativen Lösungen, welche in der Literatur unter dem Sammelbegriff der „Smart City“ geführt werden [2, 3]. Auch

hier wird die Nutzung von Schaltzeitprognosen als ein Forschungsfeld mit hohem Potential zur Verbesserung der innerstädtischen Mobilität betrachtet. So stellt die Ampelassistentz z.B. in dem vom Bundesministerium für Wirtschaft und Technologie zu 50% geförderten Projekt UR:BAN (Urbaner Raum: Benutzergerechte Assistenzsysteme und Netzmanagement) einen wichtigen Teilbaustein dar [4].

1.1 Vision Smart City: Städteseitige Treiber der Ampelassistentz

Im Jahre 2050 werden neun Milliarden Menschen auf der Erde leben, 70% davon in Städten - so motiviert das „Fraunhofer Zentrum für Smart Cities“ Urbanisierung, Globalisierung und demographische Veränderung. Diese Faktoren stellen immer höhere Anforderungen an die Stadt, gleichzeitig schaffen diese aber auch große Chancen, effizient mit Energie-, Material- und Humansressourcen umzugehen [2]. Um diese Chancen, aber auch Herausforderungen zu meistern, müsse sich die Stadt zunehmend als Dienstleister für ihre Bürger und Unternehmen präsentieren. Insbesondere müsse hierfür die Integration von Informations- und Kommunikationssystemen in die bestehenden Systeme vorschreiten. Hierdurch kann die Flexibilität der Steuerung und Koordinierung von Versorgungsnetzen, aber auch neue Lösungen für Mobilität und Sicherheit ermöglicht werden. Diese Rahmenbedingungen bilden das Grundgerüst einer „Smart City“. So definieren die Spezialisten des Fraunhofer Instituts die Smart City als eine „informierte, vernetzte, mobile, sichere und nachhaltige Stadt“.

Besondere Herausforderungen sind bei der Bekämpfung der CO₂-Emissionen zu erwarten. Insbesondere große Städte und Ballungsräume kämpfen mit den Belastungen hoher CO₂ Emissionen. Sie alleine sind für etwa 70% des weltweiten CO₂ Ausstoßes verantwortlich [5]. Weltweit wird bis 2020 ein Anstieg des ausschließlich verkehrsbedingten CO₂ Ausstoßes von derzeit etwa 7 auf etwa 9 Gigatonnen jährlich erwartet [6]. Dabei macht der verkehrsbedingte CO₂ Ausstoß etwa 26% des Gesamtausstoßes aus [7]. Neben Städten wie Toronto (Kanada) oder Pasadena (USA) gehört auch Berlin zu den Spitzenreitern in der CO₂-Emission [8]. Viele Städte haben diese Problematik bereits erkannt und beginnen zu handeln. Unter dem Stichwort „Smart City“ soll auch in diesem Bereich nach Lösungen gesucht werden. So soll die Mobilität in Städten nicht nur sicherer und flexibler gestaltet werden, sondern auch effizienter. Besonders große Bedeutung wird dabei der Kommunikation zwischen Fahrzeugen und Verkehrsinfrastruktur zu Teil [2]. Erklärte Ziele sind unter anderem auch, das Fahrverhalten in einen emissionsärmeren Stil zu verändern [6]. In urbanen Räumen gilt die Lichtsignalanlage in ihrer Aufgabe der Steuerung von Verkehrsströmen als der Hauptfaktor für viele Staus und Unfälle, aber auch für erhöhten Schadstoffausstoß wieder beschleunigender Fahrzeuge. Mit dem Wissen über das zukünftige Signalverhalten von Lichtsignalanlagen können

diese negativen Nebeneffekte abgemildert werden. Etwa kann die Fahrzeuggeschwindigkeit mithilfe einer Grünband-Geschwindigkeitsempfehlung so angepasst werden, dass ein Halt an der Kreuzung vermieden wird. Ferner bestehen die technischen Möglichkeiten, Rotlicht-Überfahrswarnung zu unterstützen, Unfälle zu vermeiden, oder mithilfe einer ampeladaptiven Route Staus an roten Ampeln zu reduzieren.

1.2 Vernetztes Fahrzeug: Fahrzeugseitige Treiber der Ampelassistentz

Stichworte wie Wettbewerbsfähigkeit, Zukunftsorientierung, Beitrag zum Markenerfolg oder Nachhaltigkeit sind die offensichtlichen Motivatoren von Innovationen im Fahrzeugbereich [9]. Neben diesen allgemeinen Zielen gibt es weitere, wesentlich konkretere Treiber der Ampelassistentzfunktionen im Fahrzeug. Diese lassen sich unterteilen in die Faktoren Fahrkomfort, Sicherheit und CO₂-Reduzierung.

Ist der Fahrer beim Halt an einer roten Ampel über die verbleibende Rotzeit informiert, so kann dieser die bisher nicht nutzbare Zeit für kleinere Tätigkeiten (etwa Verstellen der Sitzposition oder ein schneller Blick zu den Kindern auf der Rückbank) nutzen. Weiß er bei Annäherung an die Ampel, dass er diese mit der aktuellen Geschwindigkeit bequem bei grün überqueren kann, so kann auch dies seinen Fahrkomfort erhöhen.

Die Fahrsicherheit kann erhöht werden, da potentielle Beschleunigungen, vielleicht auch über das erlaubte Geschwindigkeitslimit, vermieden werden können. Auch eine Warnung bei potentiellen Rotlichtverstößen wird als ein Faktor zur Sicherheitssteigerung im Straßenverkehr diskutiert [4].

Einen großen Mehrwert verspricht man sich von Kraftstoff- und CO₂-Einsparungen mithilfe der Ampelassistentz. Durch eine auf den Signalzustand der Ampel optimierte Verzögerung etwa können Stopps an der Kreuzung vermieden und so Kraftstoff eingespart werden. Auch eine Abstimmung der Motor-Start-Stopp-Automatik wird zu einer weiteren Reduzierung des Kraftstoffverbrauches beitragen. Hierzu existieren bereits mannigfaltige Untersuchungen, die in den Quellen [10, 11, 12, 13] beschrieben werden.

Nicht nur die reale CO₂-Reduzierung in der Serie, sondern auch eine mögliche Anrechnung auf den CO₂-Flottenausstoß stellt einen Anreiz für Fahrzeughersteller dar. Zum Zweck der Umsetzung der langfristigen Vision einer CO₂-armen Wirtschaft hat die EU Maßnahmen, wie die Verordnung (EG) 443/2009 des Europäischen Parlaments und des Rates vom 23. April 2009 zur Erreichung festgelegter Zielwerte für Personenkraftwagen [14], beschlossen. Im Rahmen dieser Verordnung ist auch die Möglichkeit einer Anrechnung sogenannter Ökoinvestitionen gegeben [15]. Die Anerkennung ist unter anderem an folgende Faktoren gebunden: Einerseits muss das CO₂-Einsparpotential über 1 g CO₂/km liegen, andererseits darf die Technologie keine der Maßnahmen

aus dem EU-Gesamtkonzept (etwa Reifendruckkontrollsystem o.ä.) darstellen. Ferner muss die Technologie neu auf dem Markt sein, im speziellen darf die Marktpenetrationsrate der Fahrzeuge mit dieser Technologie maximal 3% betragen [15]. Von der Industrie wurde 2009 beispielhaft der „Eco-Mode“ als derartige Funktion angeführt. Auch die Einsparpotentiale mithilfe intelligenter Ampelassistentenfunktionen, wie z.B. die Optimierung der Motor-Start-Stopp-Automatik oder ideale Verzögerungsstrategien können hier als Öko-Investition angerechnet werden. Konkrete Einigungen gibt es derzeit jedoch noch nicht.

1.3 Aufgabenstellung und Ziel der Arbeit

Ziel dieser Arbeit ist die Erforschung und technische Konzeption von Schaltzeitprädiktionen mithilfe von Crowdsourcing-Daten und Routenoptimierung in urbanen Räumen. Mit diesen Informationen soll der Fahrer in bestimmten Situationen im Straßenverkehr unterstützt werden (etwa durch Angabe einer verbleibenden Wartezeit an einer Ampel) und gleichzeitig der CO₂-Ausstoß gesenkt werden. Darüber hinaus soll untersucht werden, wie Routen mithilfe der Informationen über zukünftige Schaltzeiten optimiert werden können. Besonderes Augenmerk wird dabei auf folgende Fragestellungen gerichtet:

- Wie können großflächig Schaltzeitprognosen verkehrsabhängiger Lichtsignalanlagen in urbanen Ballungsräumen mithilfe von Schaltzeitinformationen von Verkehrszentralen erzeugt werden? Welche Eigenschaften müssen von Verkehrszentralen oder Städten bereitgestellte Daten mitbringen, um Schaltzeitprognosen mit ausreichender Qualität zu ermöglichen? Welche Daten können mit der derzeitigen Infrastruktur von Verkehrszentralen und Städten bereitgestellt werden? Wie kann ein effizienter und skalierbarer Algorithmus zur Prognose von Schaltzeiten konzipiert werden? Welche Ergebnisse können in einer Referenzstadt erzielt werden?
- Können mithilfe von gesammelten Daten aus der Fahrzeugflotte (etwa Floating Car Data) Schaltzeiten von festzeitgesteuerten und leicht verkehrsabhängigen Lichtsignalanlagen gelernt werden? Wie viele Fahrzeuge müssen über diese Technologie verfügen (Abdeckung), um valide Rekonstruktionen des Ampelverhaltens durchführen zu können? Wie sieht die Ausgestaltung von Algorithmen zur Extraktion dieser Informationen aus den Rohdaten aus?
- Können Routenempfehlungen im Fahrzeug mithilfe verfügbarer Informationen über zukünftige Schaltzeiten optimiert werden? Wie hoch fällt der zu erwartende Reisezeitgewinn bei Routen, welche auf die Schaltzeiten an Ampeln optimiert wurden (ampeladaptive Routen) aus? Sind Schaltzeitschätzungen und Prognosen, wie sie aus den ersten beiden Fra-

gestellungen abgeleitet werden konnten, für eine Optimierung der Route ausreichend?

Die Aufgabenstellung umfasst darüber hinaus eine Backend-basierte Implementierung der konzipierten Ansätze zur Schaltzeitprognose und einer Kommunikationsschnittstelle zur Übertragung der Prognosen an Versuchsträger der BMW-Group.

1.4 Vorgehensmodell und Struktur der Arbeit

Zunächst erfolgt eine grundlegende Beschreibung und Analyse der Problemdomänen von Ampelassistenzsystemen, dem Verkehr der Zukunft, Verkehrssteuerungssysteme, Floating Car Data und der Graphentheorie in Kapitel 2. Diese Teilbereiche stellen die Grundlage für die individuellen Forschungsfragen im Rahmen dieser Arbeit dar, welche in den Kapiteln 3, 4 und 5 erörtert werden. In Kapitel 3 wird ein Verfahren zur vernetzten Schaltzeitprognose mittels Kommunikation zwischen Fahrzeugen und der Verkehrsinfrastruktur vorgestellt. Im Rahmen eines Kooperationsprojektes mit dem Kreisverwaltungsreferat München wird das vorgestellte Prognoseverfahren für die Referenzstadt München implementiert und evaluiert.

In Kapitel 4 wird zunächst das Potential der Floating Car Data-Technologie hinsichtlich der Nutzbarkeit zum Lernen der Schaltzeiten von Lichtsignalanlagen untersucht (Abschnitt 4.3.1). In Abschnitt 4.3.3 wird sodann ein Modell zur Schätzung von Umlaufzeiten an Lichtsignalanlagen und Freigabe- sowie Sperrbeginn einzelner Signalgruppen unter Verwendung aufgezeichneter Floating Car Daten vorgestellt.

Aufbauend auf den Ergebnissen aus den Kapiteln 3 und 4 wird in Kapitel 5 ein Modell zur Umsetzung einer intelligenten und dynamischen Routingstrategie unter Einbeziehung zukünftiger Schaltzeiten vorgestellt und hinsichtlich des voraussichtlichen Reisezeitgewinns im realen Umfeld bewertet.

1.5 Vorveröffentlichungen

Die Inhalte dieser Arbeit wurden in Teilen bereits auf internationalen Konferenzen, in Form von Buchbandbeiträgen oder Journalbeiträgen publiziert. Im Folgenden wird ein Überblick über diese bereits vorveröffentlichten Inhalte, sowie des jeweiligen Beitrages des Autors der vorliegenden Arbeit (im Folgenden nur noch als „Autor“ bezeichnet). In den entsprechenden Kapiteln an späterer Stelle folgt eine genauere Auflistung der bereits vorveröffentlichten Inhaltsteile.

Für alle Vorveröffentlichungen gilt, dass Prof. Dr. Claudia Linnhoff-Popien, als Lehrstuhlinhaberin und Doktormutter des Autors, beratend und als Kritikerin insbesondere an den jeweiligen Manuskripten, in denen sie als Autorin aufgeführt ist, mitgewirkt hat.

In den ersten Teil dieser Arbeit („Lernen von Signalisierungszuständen mit historischen Daten“, Kapitel 3) flossen insbesondere folgende Vorveröffentlichungen ein:

- **V. Protschky, K. Wiesner, and S. Feit, “Adaptive traffic light prediction via kalman filtering,” in *Intelligent Vehicles Symposium Proceedings, 2014 IEEE*, pp. 151–157, June 2014 [106]:**

In dieser Veröffentlichung wurde ein Konzept zur Prognose zukünftiger Signalzustände verkehrsabhängiger Lichtsignalanlagen mithilfe vergangener Schaltzeiten durch Anwendung des Kalman Filter vorgestellt. Die Evaluation erfolgte anhand sechs Münchener Lichtsignalanlagen.

Der Abschnitt 3.4.2, in welchem eigene Vorarbeiten vorgestellt werden, die nicht zum Forschungsbereich im Rahmen der Dissertation gehören, basiert auf den Inhalten dieses Manuskripts. Hierbei werden Forschungsergebnisse vorgestellt, die hauptsächlich im Rahmen meiner Masterarbeit entstanden sind. Die Entwicklung der Modelle und Evaluation, sowie Abfassung des Manuskriptes erfolgte durch mich. Die Co-Autoren standen beratend zur Seite.

- **V. Protschky, S. Feit, and C. Linnhoff-Popien, “Extensive traffic light prediction under real-world conditions,” in *Vehicular Technology Conference (VTC Fall), 2014 IEEE 80th*, pp. 1–5, Sept 2014 [105]:**

Hier wurde ein Verfahren zur effizienten und skalierbaren Prognose zukünftiger Signalzustände verkehrsabhängiger Lichtsignalanlagen gesamter urbaner Ballungsräume mithilfe vergangener Schaltzeiten vorgestellt. Die Evaluation erfolgte anhand von ca. 700 Münchener Lichtsignalanlagen. Abschnitt 3.5 basiert hauptsächlich auf den Inhalten dieser Veröffentlichung. Die Entwicklung und Umsetzung der Modelle und die Evaluation, sowie die Abfassung des Manuskriptes erfolgte durch mich. Stefan Feit stand beratend zur Seite.

- **D. Irschik, V. Protschky, and F. Schweizer, “Kooperative Systeme im Straßenverkehr auf Basis einer Client-Server-Architektur” *Strassenverkehrstechnik*, vol. 58, no. 10, 2014 [104]:**

In dieser Veröffentlichung wurden die Nutzung kooperativer Systeme zur Risikoreduktion, CO₂-Ersparnis und Steigerung des Fahrkomforts aufgezeigt. Die Autoren Irschik und Schweizer beleuchteten dabei den Aspekt der Risikoreduktion, ich erläuterte potentielle CO₂-Ersparnisse und Steigerung des Fahrkomforts anhand der Kundenfunktion Ampelassistentz. Abschnitt 3.5 enthält kleinere Teile dieser Arbeit.

- **V. Protschky and S. Feit, “Traffic Light Assistance – ein innovativer Mobilitätsdienst im Fahrzeug,” in *Marktplätze im Um-***

bruch (C. Linnhoff-Popien, M. Zaddach, and A. Grahl, eds.), Xpert.press, pp. 579–587, Springer Berlin Heidelberg, 2015 [103]:

Im Rahmen dieser Arbeit wurden die Möglichkeiten, welche sich durch neue Marktplätze wie dem Mobilitäts-Datenmarkt (MDM), für Kundenfunktionen wie den Ampelassistenten ergeben, untersucht. Die Abfassung des Manuskriptes erfolgte durch mich. Stefan Feit stand beratend zur Seite. Abschnitt 3.5 enthält kleinere Teile dieser Arbeit.

Für den zweiten Teil der Arbeit („Lernen von Signalisierungszuständen mit Floating Car Data“, Kapitel 4) bilden folgende Veröffentlichungen die Basis:

- V. Protschky, P. Seifert, and S. Feit, “Stop line detection using satellite-image segmentation,” in *Vehicular Technology Conference (VTC Spring), 2015 IEEE 81st*, pp. 1–5, May 2015 [102]:

Insbesondere zur Rekonstruktion von Schaltzeiten mithilfe von FCD ist die Kenntnis über eine möglichst genaue Haltelinienposition unabdingbar. In dieser Arbeit wurde ein Verfahren zur Bildverarbeitung von Satellitenbildern vorgestellt, um Haltelinienpositionen zu extrahieren. Die Auswahl und Anwendung geeigneter Bildverarbeitungsalgorithmen zur Extraktion von Haltelinien und deren Position wurden im Rahmen der Bachelorarbeit von Paul Seifert unter der Betreuung von Stefan Feit und mir durchgeführt. Der Versuchsaufbau und Evaluation wurden von mir vorgegeben und betreut. Die Abfassung des Manuskriptes erfolgte ebenfalls durch mich. Abschnitt 4.3.3 enthält kleinere Teile dieser Arbeit.

- V. Protschky, S. Feit, and C. Linnhoff-Popien, “On the potential of floating car data for traffic light signal reconstruction,” in *Vehicular Technology Conference (VTC Spring), 2015 IEEE 81st*, pp. 1–5, May 2015 [101]:

Diese Veröffentlichung beinhaltet die Untersuchung von Floating Car Data zur Nutzung für die Signalzustandsschätzung an Lichtsignalanlagen. Es wurden erste Verfahren zur Umlaufzeitrekonstruktion und Phasenschätzung vorgestellt und ein Zusammenhang zwischen Anzahl verfügbarer FCD und Qualität einer Signalzustandsschätzung hergestellt.

Abschnitt 4.3.1 basiert hauptsächlich auf den Inhalten dieser Veröffentlichung. Die Entwicklung der Modelle und Evaluation, sowie Abfassung des Manuskriptes erfolgte durch mich. Stefan Feit stand beratend zur Seite.

- V. Protschky, C. Ruhhammer, and S. Feit, “Learning traffic light parameters with floating car data,” in *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 2438–2443, Sept 2015 [99]:

Hier wurde ein konkretes Lernverfahren zur Rekonstruktion von Lichtsignalparametern vorgestellt. Dazu wurden durch den Autor große Mengen an FCD verarbeitet und ausgewertet. Anschließend erfolgte die Konzeption von Lernalgorithmen zur Schätzung wahrscheinlichster Signalparameter. Abschnitt 4.3.3 basiert zu großen Teilen auf den Inhalten dieser Veröffentlichung. Die Entwicklung der Modelle und Evaluation, sowie Abfassung des Manuskriptes erfolgte durch mich. Stefan Feit und Christian Ruhhammer standen beratend zur Seite.

Das ampeladaptive Routing, das im dritten Teil der vorliegenden Arbeit betrachtet wird (Kapitel 5), basiert im Wesentlichen auf der folgenden Veröffentlichung.

- **V. Protschky, S. Feld, and M. Wälischmiller, “Traffic signal adaptive routing,” in *Intelligent Transportation Systems (IT-SC)*, 2015 *IEEE 18th International Conference on*, pp. 450–456, Sept 2015 [100]:**

Im Rahmen dieser Veröffentlichung wurde ein Verfahren zur Berechnung dynamischer Routen entworfen, das zukünftige Schaltzeiten an Lichtsignalanlagen berücksichtigt. Ziel ist durch die Berechnung sogenannter „ampeladaptiver Routen“ einen Reisezeitgewinn zu realisieren. Kapitel 5 basiert zu großen Teilen auf den Inhalten dieser Veröffentlichung. Die Ideen und Konzeption der Verfahren, sowie Abfassung des Manuskriptes erfolgte durch mich. Die Implementierung der Verfahren erfolgte zu großen Teilen durch M. Wälischmiller im Rahmen seiner Bachelorarbeit, welche von mir und Sebastian Feld betreut wurde. Bei der Abfassung des Manuskriptes und der Durchführung der Evaluation durch mich stand Sebastian Feld beratend zur Seite.

2 Grundlagen der Ampelassistentz

Diese Arbeit gliedert sich in drei Themengebiete. Dieses Kapitel fasst die Grundlagen aller Teilbereiche zusammen und erörtert relevante Grundlagen.

Zunächst wird auf derzeitige Assistenzfunktionen im Fahrzeug und deren Klassifikation eingegangen. Sodann werden der Entwurf von Lichtsignalprogrammen und gängige Steuerungsverfahren, sowie länderspezifische Aspekte in der Programmierung von Lichtsignalanlagen beschrieben. Anschließend werden die Grundlagen von Floating Car Data gelegt. Schließlich werden noch grundlegende Aspekte des Routings in Graphen beleuchtet.

2.1 Übersicht über Assistenzfunktionen

In modernen Fahrzeugen kommt bereits eine Vielzahl unterschiedlicher Assistenzfunktionen zum Einsatz. Dabei reicht die Spannweite von Systemen zur Erhöhung der Sicherheit wie Notbremsassistenten über Navigationssysteme bis hin zu Stauassistenten, welche die Fahraufgabe im Stau übernehmen. Nachfolgend wird ein Überblick über allgemeine Assistenzfunktionen und die Eingliederung der Ampelassistentz in diese dargestellt.

2.1.1 Allgemeine Assistenzfunktionen

Fahrerassistenzfunktionen unterscheiden sich typischerweise nach ihrem Automatisierungsgrad. Sie können nur informative Hilfestellungen geben (etwa Stauinformationen) oder z.B. regelnd eingreifen (etwa mittels Autonomous Cruise Control). Eine Klassifizierung nach unterschiedlichen Automatisierungsgraden wurde bereit 1999 durch Donges durchgeführt [16], dargestellt in Abbildung 2.1. Informationen (oberste Ebene) sollen den Fahrer lediglich unterstützen, etwa durch Anzeige einer zulässigen Höchstgeschwindigkeit oder einer Routenempfehlung, während Warnungen und Aktionsempfehlungen (Action Recommendation) bereits unmissverständliche Handlungsempfehlungen geben sollen (etwa Notbrems-Warnung). Die Fahrdynamikregelung (Vehicle Dynamics Control) stabilisiert das Fahrzeug (etwa ABS oder ESP). Teilweise automatisierte Systeme (Partial Automation) übernehmen bestimmte Fahraufgaben, wie es etwa beim Autonomous Cruise Control (ACC) der Fall ist. Im Gegensatz zum vollautomatisierten Assistenzfunktion (Full Automation) entscheidet jedoch der Fahrer über die Aktivierung der Funktion. Ein Beispiel für

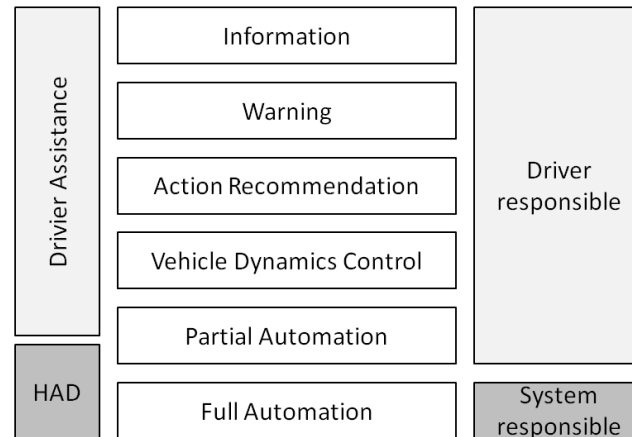


Abbildung 2.1: Klassifizierung von Fahrerassistenzfunktionen nach [16].

einen solchen vollautomatisierten Eingriff ist der Notbrems-Eingriff. Auch in anderen Werken finden sich Klassifizierungen, die sich jedoch nur marginal von der von Donges unterscheiden. So beschreibt die Bundesanstalt für Straßenwesen (BaST)-Gruppe vier verschiedene Automatisierungsgrade [17]. Durch Winner et al. werden drei Kategorien von Fahrerassistenzfunktionen (informierende und warnende Funktionen, kontinuierlich automatisierende Funktionen und eingreifende Notfallfunktionen) definiert [18].

2.1.2 Ampelassistentenzfunktionen

Ampelassistentenzfunktionen können je nach konkreter Assistenzfunktion in allen Kategorien auftreten. Nachfolgend wird, ohne Anspruch auf Vollständigkeit, eine Auflistung und Erörterung der aktuell diskutierten Ampelassistentenzfunktionen dargestellt.

- **Ampel-Statusinformationen:** Hierbei handelt es sich um informative Unterstützungsfunktionen für den Fahrer. Ziel ist es, dem informierten Fahrer mehr Sicherheit und Fahrkomfort zu bieten, in dem er durch die erhaltenen Informationen vorausschauender agieren kann. So soll er sich auf Rotphasen bei Ankunft an der Ampel bereits bei Anfahrt einstellen können, oder die Information erhalten, wie lange der aktuelle Signalzustand noch anhält. Ampel-Statusinformationen können wie folgt weiter aufgegliedert werden:
 - **Anzeige der verbleibenden Rotphase:** Bei dieser Funktion wird dem Fahrer sowohl bei Annäherung an eine Ampel, als auch bei Stand vor dieser die voraussichtlich verbleibenden Rotphase angezeigt. Der Nutzen für den Fahrer unterscheidet sich zwischen Fahrt und Stand - so kann er bei Stillstand die verbleibende Wartezeit nutzen, um kleinere, straßenverkehrsrechtlich erlaubte Tätigkeiten, wie z.B. das Ändern des Navigationsziels, durchzuführen. Während

der Fahrt kann der Fahrer u.U. die Information der verbleibenden Rotzeit nutzen, um so weit zu verzögern, dass sich ein Halt vermeiden lässt - dies würde zur Reduktion des CO₂-Ausstoßes beitragen.

- **Anzeige der verbleibenden Grünphase:** Dies ermöglicht dem Fahrer, abzuschätzen, ob die aktuelle Grünphase ausreichend ist, die entsprechende Lichtsignalanlage bei grün zu passieren. Diese Information kann gegebenenfalls auch mit der Prepare-to-Stop-Information verknüpft werden, die anzeigt, dass die Überquerung der Lichtsignalanlage bei grün nicht mehr möglich ist.
- **Prepare-to-Start Information:** Die Funktion macht den Fahrer bei Stand darauf aufmerksam, dass die vor ihm befindliche Ampel bald auf grün schalten wird. Eine Kombination mit der Anzeige der verbleibenden Rotphase ist sinnvoll.
- **Prepare-to-Stop Information:** Hier wird dem Fahrer angezeigt, dass die Überquerung der Lichtsignalanlage bei grün nicht mehr möglich ist. Errechnet wird dies anhand der Distanz zur Haltelinie, verbleibender Grünzeit und der maximal zulässigen Höchstgeschwindigkeit.
- **Anzeige der benötigten Grünphasen zur Überquerung der Ampel bei Rückstau:** Speziell in Starkverkehrszeiten ist es möglich, dass eine Grünphase nicht zur Überquerung der jeweiligen Lichtsignalanlage ausreicht, da der Rückstau zu groß ist. Es kann dem Fahrer einen Mehrwert bieten, ihn darüber zu informieren, ob die derzeitige Grünphase für eine Überfahrt bei grün ausreichend ist, bzw. wie viele Grünphasen er noch benötigen wird.

Die individuellen Funktionen sind in Abbildung 2.2 zusammengefasst. Dabei wird zusätzlich zwischen den Kategorien „Stand“/Stop-and-Go“ und „Fahrt“, sowie den Signalzuständen rot und grün und dem Wechsel zwischen ihnen unterschieden. Entsprechend des Szenarios ist die jeweilige Assistenzfunktion, sowie ein Vorschlag zur Darstellung im Fahrzeug dargestellt.

- **Geschwindigkeits- oder Verzögerungsempfehlungen:** Entgegen der Anzeige der verbleibenden Grünphase informiert die Grünband-Geschwindigkeitsempfehlung bzw. Verzögerungsempfehlungen den Fahrer anhand eines Grünbandes über den Geschwindigkeitsbereich, in dem er die Ampel bei grün überqueren kann. Hier muss der Fahrer nicht mehr selbst abschätzen, ob die verbleibende Grünphase für das Überqueren bei grün ausreicht.
- **Anfahrtserinnerung:** Ist der Fahrer bei Stillstand vor der Ampel un-aufmerksam und bemerkt den Wechsel auf grün nicht, weist ihn die Anfahrtserinnerung audio-visuell darauf hin.


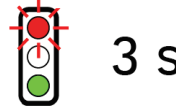


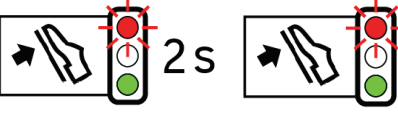

| | Ampel bleibt rot | Ampel wechselt von grün auf rot | Ampel wechselt von rot auf grün | Ampel bleibt grün |
|-------------------------------|---|--|---|--|
| Stand/ Stop-and-Go | Standphase vor roter Ampel. Anzeige der verbleibenden Rotdauer  32 s | Stauschieben vor Ampel, die nicht passiert werden wird/kann. Anzeige der verbleibenden Gründauer  3 s | cMSA: Motorstart vor Gelbphase / Urban Launch Control. Restrotanzeige, Prepare to start  3 s | Standphase vor grüner Ampel mit anschließender Fahrt: Anzeige der Grünphase  200 m |
| Fahrt | Effizientes Verzögern bis zum Stand (SRA). Prepare to stop Anzeige der verbleibenden Grün- oder Rotdauer  2 s | Grüne-Welle-Assistent (oder SRA) um grüne Ampel - ohne ineffiziente Brems- oder Beschleunigungsvorgänge - zu passieren. Anzeige der Grünphase oder verbleibende Rotdauer  200 m | | |

Abbildung 2.2: Ampelassistentenfunktionen und entsprechende HMI-Vorschläge im Überblick.

- **Rotlicht-Überfahrenswarner:** Bewegt sich der Fahrer mit hoher Geschwindigkeit auf eine Ampel zu, die bei Ankunft rot sein wird und ist abzuschätzen, dass bei Beibehalt der aktuellen Fahrt-Trajektorie ein Rotlichtverstoß auftreten wird, so warnt der Rotlicht-Überfahrenswarner den Fahrer rechtzeitig.
- **Grüne-Welle-Routing:** Mit dem Grüne-Welle-Routing (auch ampeladaptives Routing genannt) soll dem Fahrer eine hinsichtlich der zukünftigen Schaltzeiten an Ampeln optimierte Routenempfehlung gegeben werden. Ziel ist es, Warte- und Standzeiten an roten Ampeln durch intelligente Routenwahl zu minimieren und so die Reisezeit und den CO₂-Ausstoß zu reduzieren.
- **ACC + Abbremsen bei roten Ampeln:** Ziel ist hier, die Funktion Autonomous Cruise Control (ACC, deutsch: Abstandsregeltempomat) mit dem Abbremsen bei roten Ampeln zu verknüpfen. Beim ACC, das bereits seit dem Jahr 2000 im Fahrzeug erhältlich ist, wird der Abstand zum vorausfahrenden Fahrzeug automatisch geregelt. Bisher können diese Systeme noch nicht selbständig an roten Ampeln zum Stehen kommen.
- **Konkrete Fahreingriffe zur Realisierung einer idealen Annähe-**

| | | | |
|-------------------|--------------------------|---|--------------------|
| Driver Assistance | Information | Ampel-Statusinformationen, Grüne-Welle-Routing | Driver responsible |
| | Warning | Anfahrts- und Rotlicht-Überfahrswarnung | |
| | Action Recommendation | Geschwindigkeits- oder Verzögerungsempfehlungen | |
| | Vehicle Dynamics Control | Konkrete Fahreingriffe zur Realisierung einer idealen Annäherungsstrategie, ACC + Abbremsen bei roten Ampeln, MSA-Connected | |
| HAD | Partial Automation | | System responsible |
| | Full Automation | Nutzung für HAD | |

Abbildung 2.3: Eingliederung der aktuell diskutierten Ampelassistentenfunktionen in die Klassifizierung von Fahrerassistenzfunktionen nach [16].

rungsstrategie: Während die zuvor beschriebene Funktion lediglich das Abbremsen an roten Ampeln beschreibt, soll beim automatisierten Eingriff in die Längsregelung des Fahrzeuges eine Idealtrajektorie berechnet und befahren werden. Hier steht das vorausschauende Fahren mit dem Ziel der Kraftstoffreduzierung und gegebenenfalls Zeiteinsparung im Vordergrund. Eine Verknüpfung mit dem Grüne-Welle-Routing und dem ACC ist denkbar.

- **Effiziente Motor-Start-Stopp-Automatik:** Fahrzeuge der neueren Generation stellen bei Stillstand automatisch den Motor zum Zwecke der Senkung des Kraftstoffverbrauches aus. Diese Funktion wird häufig als Motor-Start-Stopp-Automatik (MSA) bezeichnet. Diese kann durch die Kenntnis der voraussichtlichen Rotzeit an einer Ampel weiter optimiert werden.

Die vorgestellten Ampelassistenzsysteme stellen Funktionen auf allen Automatisierungsebenen nach Donges [16] dar. Abbildung 2.3 zeigt die Eingliederungen der individuellen Ampelassistenzsysteme in die entsprechenden Kategorien auf.

2.2 Projekte zum Verkehr der Zukunft

Die Idee einer Smart City, in der Städte mit Dritten kommunizieren und interagieren, um bedarfs- und situationsgerechte Lösungen zu finden, ist nicht mehr nur eine ferne Vision. Es gibt bereits Projekte in der Forschung, die das Ziel haben, mögliche Konzepte auszuarbeiten. Ein Forschungsprojekt mit dem Ziel, den Verkehr der Zukunft sicherer und effizienter zu gestalten, ist das Projekt UR:BAN, in dem sich viele Partner aus Industrie und öffentlicher Hand zusammengeschlossen haben, um gemeinsam neue Fahrerassistenz-

und Verkehrsmanagementsysteme zu entwickeln. Auch Bestrebungen, einen gemeinsamen Datenmarktplatz für Verkehrsdaten zu etablieren, wurden mit dem Mobilitätsdatenmarktplatz [19] aufgenommen. Darüber hinaus gab es bereits frühere Projekte zur effizienteren Gestaltung des Verkehrs in Städten, aber auch auf Bundes- und Staatsstraßen, wie etwa das Projekt KOLIBRI. Im Folgenden wird eine Übersicht der Projektlandschaft dargestellt.

2.2.1 MDM

Beim Mobilitätsdatenmarkt (MDM) handelt es sich um eine neutrale B2B-Plattform zum Zweck des bundesweiten Austausches von Informationen über Verkehrsströme, Staus, Baustellen, Kraftstoffpreise, Parkmöglichkeiten, und Schaltzeitinformationen. Gegründet wurde die Plattform im Jahr 2007 durch das Bundesministerium für Verkehr und digitale Infrastruktur, sowie der Bundesanstalt für Straßenwesen und ging 2011 in den Testbetrieb. Der MDM soll einen leichteren Datenaustausch zwischen den Partnern im Verkehr ermöglichen und so den Weg für die Entwicklung neuer Assistenzsysteme und einem besseren Verkehrsmanagement ebnen [19].

2.2.2 UR:BAN

Im Rahmen der Forschungsinitiative Urbaner Raum: Benutzergerichte Assistenzsysteme und Netzmanagement (UR:BAN) haben sich von 2012 bis Anfang 2016 31 Vertreter aus der Automobil- und Zulieferindustrie, aus Universitäten, Forschungsinstituten und Städten zusammengefunden, um neue Fahrerassistenz- und Verkehrsmanagementsysteme für die Stadt zu entwickeln. Die Forschungsarbeiten wurden dabei in drei Themenschwerpunkte unterteilt:

- **Kognitive Assistenz:** Dieser Themenschwerpunkt befasst sich mit der „Erhöhung der Sicherheit im städtischen Verkehr durch die kontinuierliche Unterstützung des Fahrers in komplexen Situationen wie zum Beispiel an Kreuzungen mit Fußgängern und Radfahrern, Engstellen, bei Gegenverkehr, sowie beim Spurwechsel“ [4]. Hier wurden Ansätze zur Vermeidung von Kollisionen durch automatisches Bremsen, sowie durch Ausweichen in erkannten Freiraum erforscht.
- **Vernetztes Verkehrssystem:** In diesem Themenbereich wird die Fahrzeugfunktion Ampelassistentenz beleuchtet. Im Rahmen dieses Themenkomplexes sollten allgemeine Ansätze zur Umsetzung dieser Funktion mittel der aktuellen Informations- und Kommunikationsmöglichkeiten wie GPS/Galileo, UMTS/LTE und C2X erforscht, aber auch anhand einer Referenzstadt demonstriert werden. Partner waren GEVAS Software, die Stadt Düsseldorf, Stadt Kassel, Universität Kassel, BMW Group, und die MAN AG. Hierbei wurden Schaltzeitprognosen durch GEVAS in Zusammenarbeit mit den Städten Düsseldorf und Kassel und der Universität Kassel erstellt. Diese wurden durch die BMW Group und MAN zur

Implementierung eines Grüne-Welle- und Verzögerungsassistenten verwendet. Eine Smartphone-Applikation wurde durch die Universität Kasel entwickelt.

- **Mensch im Verkehr:** Im Fokus stand der Mensch in all seinen Rollen im Verkehr. Hier wurden neue Methoden zur Erforschung des menschlichen Verhaltens entwickelt, um seine Absichten (etwa durch Kopfbewegungen) rechtzeitig zu erkennen und zu deuten. Ziel ist es, beispielsweise Fahrmanöver wie Abbiegen oder Fahrspurwechsel, vorauszusagen.

2.2.3 Frühere Forschungsprojekte

Neben dem bislang größten bekannten Forschungsprojekt UR:BAN gab es bereits schon frühere Projekte zur Optimierung des Fahrzeugverkehrs.

KOLIBRI: Im Forschungsprojekt Kooperative Lichtsignaloptimierung - Bayerisches Pilotprojekt (KOLIBRI) von 2010 bis 2012 wurde anhand zweier Teststrecken (B13 in München und St2145 in Regensburg) untersucht, wie auf Außerortsstraßen die Schaltungen von Ampelanalgen besser koordiniert werden können, um Verkehrsteilnehmer besser zu informieren sowie Staus zu vermeiden. Besonderes Augenmerk wurde auf das Verhalten und die Vorhersage des Pulkverhaltens von Fahrzeugen gelegt, welches als die maßgebliche Größe für eine funktionierende grüne Welle gilt [20].

AKTIV: Im Projekt Adaptive und kooperative Technologien für den intelligenten Verkehr (AKTIV) wurden zwischen 2007 und 2010 technische Grundlagen für die Kommunikation zwischen Fahrzeugen und Lichtsignalanlagen geschaffen. Dazu wurden Informationen zwischen Lichtsignalanlage und Fahrzeugen ausgetauscht (C2I und I2C-Kommunikation), um einfache Anwendungen wie Zeitauern bis zum nächsten Signalwechsel an lokalen Lichtsignalanlagen zu testen und zu demonstrieren. Gezeigt wurde dies anhand von Einzelanlagen [21].

Sim-TD: In dem Projekt Sichere intelligente Mobilität Testfeld Deutschland (Sim-TD) haben sich 2011 bis 2013 diverse Unternehmen der Automobil- und Telekommunikationsbranche, die hessische Landesregierung Universitäten und Forschungsinstitute als Partner zusammengeschlossen. Ziel war ebenfalls die Erforschung und Erprobung der Car-to-X-Kommunikation und ihrer Anwendung in der sicheren und intelligenten Mobilität. Insbesondere wurden die Lokale Gefahrenwarnung, Fahrerassistenz und Verkehrsflusssteuerung untersucht [22].

TRAVOLUTION: Das Projekt TRAVOLUTION der Partner Audi, TUM und GEVAS fand von 2008 bis 2009 statt und war in zwei Teilprojekten or-

ganisiert: Zum einen wurde eine netzweite Online-Optimierung der Lichtsignalsteuerung im Teilprojekt GALOP erarbeitet. In einem zweiten Teilprojekt („Der informierte Fahrer“) fand die WLAN-basierte Entwicklung eines Ampelassistentensystems anhand von 50 Lichtsignalanlagen in Ingolstadt statt. Hier wurde dem Fahrer einerseits eine Restrotzeit an der nächsten Lichtsignalanlage sowie die optimale Geschwindigkeit für die freie Passierbarkeit des nächsten Lichtsignalgesteuerten Knotens übermittelt [23].

KOLINE: In dem Projekt Kooperative und optimierte Lichtsignalsteuerung in städtischen Netzen (KOLINE) von 2011 bis 2012 liegt der Schwerpunkt auf dem automatischen Anfahren bzw. Durchfahren von Lichtsignalanlagen im städtischen Netz. Auch hier steht der Nachweis der technischen Machbarkeit des Systems im Fokus [24].

2.3 Verkehrssteuerung

Zur Steuerung des Verkehrsflusses im Straßenverkehr gibt es eine Vielzahl von Einflussgrößen. So sind hier beispielsweise Regelungen der zulässigen Höchstgeschwindigkeit, mehrspuriger Ausbau von Fahrbahnen, Optimierung von Schaltzeiten an koordinierten Verkehrsknoten oder Grüne Wellen anzuführen. Da der Aus- und Umbau von Fahrbahnen in urbanen Ballungsräumen sehr begrenzt ist, stellt die Haupteinflussgröße die Koordinierung von Verkehrsflüssen an Knotenpunkten dar. Üblicherweise erfolgt dies durch Lichtsignalanlagen.

2.3.1 Fachbegriffe von Lichtsignalanlagen

Es erfolgt eine Auflistung der wichtigsten Fachbegriffe von Lichtsignalanlagen.

Lichtsignalanlage: Unter dem Begriff Lichtsignalanlage (LSA) werden sämtliche Komponenten einer Ampelanlage eines Verkehrsknotenpunktes verstanden. Sie dient insbesondere der Verbesserung der Verkehrssicherheit und der Qualität des Verkehrsablaufes an Verkehrsknotenpunkten [25]. Illustrativ ist dies in Abbildung 2.4 dargestellt.

Signalgeber: Der Signalgeber wird umgangssprachlich als Ampel bezeichnet. Er regelt die Freigabe oder Sperrung für einen individuellen Verkehrsstrom an einem koordinierten Verkehrsknotenpunkt.

Signalgruppe: Zu einer Signalgruppe (SG) können alle Signalgeber zusammengefasst werden, die gleich geschaltet werden dürfen. Üblicherweise besteht eine Signalgruppe aus mehreren Signalgebern, die in gleicher Weise gesteuert werden. Abbildung 2.4 illustriert die Situation an einem Verkehrsknotenpunkt. Signalgruppen sind gleich gefärbt.

Signalprogramm: Im Signalprogramm sind die Dauer und die Zuordnung von Freigabe- und Sperrzeiten zu Verkehrsströmen geregelt. Grundsätzlich wird festgelegt, welche Verkehrsströme es gibt (diese werden in Signalgruppen

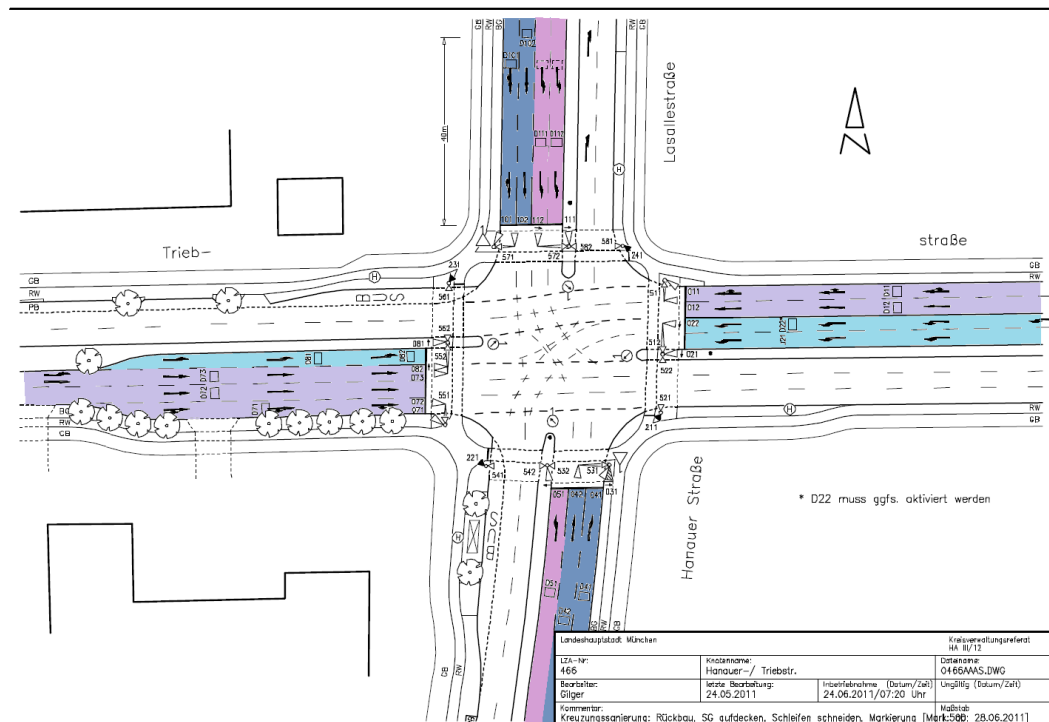


Abbildung 2.4: Signallageplan der Kreuzung Hanauerstr./Triebstr (LSA 466). Gleiche Signalgruppen sind in gleicher Färbung dargestellt.

zusammengefasst), in welcher Reihenfolge diese bedient werden (Phasenabfolge) und Zwischenzeiten sowie Mindestfreigabezeiten definiert.

Phase: Die Phase ist der Zeitraum, während dessen ein bestimmter Signalzustand (Freigabe „grün“/Sperrung „rot“) bestehen bleibt.

Phasenfolge: Die Phasenfolge beschreibt die Reihenfolge, in der bestimmte Signalgruppen bedient werden. So muss, insbesondere bei komplexen Knotenpunkten, die Abfolge von Freigabe- und Sperrzeiten der Signalgruppen festgelegt sein.

Umlaufzeit: Als Umlaufzeit wird die Zeitdauer bezeichnet, die benötigt wird, bis jede Signalgruppe eine Freigabezeit erhalten hat. Dies beinhaltet auch die Schutzzeiten (Nicht-Grün-Zeiten zum Räumen von Verkehrsknotenpunkten).

Phaseneinsatzpunkt: Der Begriff *Phaseneinsatzpunkt* beschreibt den Bereich, innerhalb dessen die Freigabe- (Sperr)zeit variieren darf. Er wird oftmals auch als *Dehnungsbereich* bezeichnet.

2.3.2 Steuerungsstrategien für Lichtsignalanlagen

Unabhängig davon, welches (länderspezifische) Verfahren zur Steuerung von Lichtsignalanlagen angewandt wird, kann zwischen zwei Steuerungsstrategien

für Lichtsignalanlagen differenziert werden: festzeitgesteuerte und verkehrshängige Steuerung von Lichtsignalanlagen.

2.3.2.1 Festzeitgesteuerte Lichtsignalanlagen

Bei den sogenannten festzeitgesteuerten Lichtsignalanlagen (im englischen als „pre-timed“ oder „fixed“ bezeichnet) wird jede Signalgruppe für eine feste und unveränderliche Dauer bedient. Die Umlaufzeit und Phasenfolge innerhalb eines Signalprogrammes sind dabei ebenfalls festgelegt und unveränderlich. Signalprogramme hingegen können jedoch auch bei festzeitgesteuerten Lichtsignalanlagen zeitplanabhängig geändert werden.

2.3.2.2 Verkehrsabhängige Lichtsignalanlagen

Verkehrsabhängige Lichtsignalanlagen können ihre Freigabe- und Sperrzeiten entsprechend des Belegungsgrades anpassen. Der Umfang der Adaptivität von verkehrshängigen Lichtsignalanlagen reicht dabei von einer quasi-Festzeitsteuerung bis hin zu einer hochadaptiven Steuerung auf Basis der aktuellen Verkehrssituation. Zur Erfassung der Verkehrsstärke und des Belegungsgrades an staugefährdeten Stellen erfolgt der Einsatz von sogenannten „Messstellen“. Diese werden üblicherweise durch Detektoren realisiert, die Infrarot- oder Videokameras, Radar oder Induktivschleifen darstellen können, während letztere am weitesten verbreitet sind. Alle Detektoren verwenden ein Verfahren zur Bemessung des Belegungsgrades/der Verkehrsstärke mithilfe von Zeitlücken. Zur Auswertung der verkehrlichen Situation können die Zeitlückewerte direkt dienen, oder alternativ der Belegungsgrad bestimmt werden. Entsprechend der Informationen hinsichtlich Belegungsgrad respektive Zeitlückewerte können nun Freigabezeiten verlängert, oder bei Nichtanforderung abgebrochen werden. Damit jeder Verkehrsstrom die Garantie hat, nach endlicher Zeit bedient zu werden, müssen dabei späteste Freigabezeitenden T_{max} berücksichtigt werden. Aus Gründen der Verkehrssicherheit wird überdies i.d.R. ein Freigabemindestzeitraum T_{min} definiert. Für den verkehrlich ermittelten Freigabeabbruch T_x gilt folglich: $T_{max} \leq T_x \leq T_{min}$.

Direkte Freigabezeitverlängerungen aufgrund des von Detektoren ermittelten Belegungsgrades stellen Anpassungen auf mikroskopischer Ebene dar. Langfristige Ungleichmäßigkeiten, z.B. in der Verkehrsbelastung, mittlerer Verkehrsdichte oder bei Emissionsgrenzwerten, können nur unzureichend durch diese mikroskopische Steuerungsverfahren abgebildet werden. Um derartige Kenngrößen beim Steuerungsverfahren einzubeziehen, werden unterschiedliche Signalprogramme definiert. Diese definieren die Regelungen, nach denen insbesondere Freigabezeitverlängerungen und Verkürzungen, sowie Phasenabfolge erfolgen, oder Umlaufzeiten festgelegt werden. Die Auswahl kann sowohl zeitabhängig, als auch verkehrshängig erfolgen. Bei zeitabhängiger Signalprogrammwahl werden zu bestimmten Tageszeiten unterschiedliche Programme geschaltet. Die verkehrshängige Programmwahl wählt hingegen ein entspre-

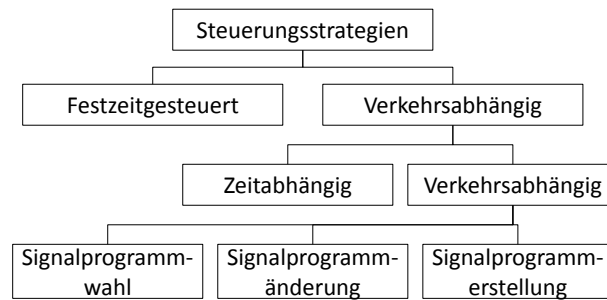


Abbildung 2.5: Steuerungsstrategien für Lichtsignalanlagen.

chend der Verkehrssituation passendes Programm aus. Auch ist eine verkehr-abhängige Programmbildung denkbar. Abbildung 2.5 stellt diesen Zusammen-hang schematisch dar.

2.3.3 Steuerungsverfahren für Lichtsignalanlagen

Die Umsetzung der Steuerungsstrategien unterscheidet sich je nach angewandtem Steuerungsverfahren. Weltweit gibt es eine Menge unterschiedlicher Steuerungsverfahren, die meist auf nationaler Ebene entstanden sind. Oftmals werden diese auch von anderen Ländern aufgrund ihres Reifegrades übernommen. Im Folgenden werden, ohne Anspruch auf Vollständigkeit, die verbreitetsten Steuerungsverfahren beschrieben.

2.3.3.1 SCOOT

Split Cycle Offset Optimisation Technique (SCOOT) ist in Großbritannien entwickelt worden. Heutzutage findet es vorwiegend in Großbritannien, aber auch in einigen Städten in den USA, Lateinamerika, Asien und dem mittleren Osten Anwendung. Ein SCOOT-Netzwerk wird in Regionen unterteilt, welche zusammenhängend gesteuert werden. Auf diesem Weg sind Koordinationen von Fahrzeugen möglich [26]. Bei SCOOT handelt es sich um ein hochadaptives Steuerungsverfahren, das mittels des gemessenen Belegungsgrades den Verkehrsfluss optimiert. Dies erfolgt auf drei Ebenen. Mikroskopische Anpassungen werden mit dem „Split Optimizer“ durchgeführt. Hier werden Freigabe- und Sperrzeiten bei Bedarf verlängert oder verkürzt. Der „Offset Optimizer“ bemisst die Abstimmung zwischen den unterschiedlichen Lichtsignalanlagen der Region in jedem Umlauf neu und verschiebt die Freigabe- und Sperrzeiten anhand eines „Offsets“ so, dass eine gute Koordination zwischen den einzelnen Lichtsignalanlagen gegeben ist. Mit dem „Cycle Time Optimizer“ können die Umlaufzeiten der Region angepasst werden. Die Anpassungsintervalle dürfen nicht kleiner als 2,5 Minuten sein [27].

2.3.3.2 SCATS

Sydney Coordinated Adaptive Traffic System (SCATS) ist ein adaptives Verkehrsmanagementsystem, das mittels Steuerung von Lichtsignalanlagen den Verkehrsfluss einer gesamten urbanen Region optimiert. Es findet in über 30 Städten Einsatz, darunter vorwiegend in Australien, Neuseeland und China [28]. Das System bietet dem Anwender eine weite Bandbreite an Kontrollstrategien. Diese umfassen tagesabhängige und tageszeitabhängige Koordinierungen im gesamten Netz, aber auch eine lokale Steuerung einzelner Knotenpunkte. Auch hier kann eine Anpassung der Freigabe- und Sperrzeiten, des Offsets und der Umlaufzeit erfolgen. Darüber hinaus ist es möglich, die Phasenabfolge dynamisch anzupassen. Die Berechnung des Verkehrsflusses erfolgt anhand des gemessenen Belegungsgrades (induktiver) Detektoren. Eine SCATS-Verkehrskontrollinstanz kann maximal 250 Kreuzungen steuern. Eine Vernetzung der Instanzen ist möglich [29].

2.3.3.3 RiLSA

Die Richtlinien für Lichtsignalanlagen (RiLSA) [25] sind das in Deutschland gültige technische Regelwerk für Planung, Entwurf und Koordinierung von Ampelanlagen. Sie werden von der Forschungsgesellschaft für Straßen- und Verkehrswesen herausgegeben. Hier ist auch der Begriff „Steuerungsverfahren“ für den deutsch Raum definiert als „das Zusammenspiel von veränderbaren Steuergrößen und Signalprogrammelementen“.

Auch im deutschen Raum wird zwischen Festzeitsteuerungsverfahren und verkehrsabhängigen Steuerungsverfahren unterschieden. Festzeitsignalprogramme finden laut RiLSA stets dort Anwendung, wo mit gleichbleibenden Belastungszuständen über längere Zeiträume zu rechnen ist. Eine mikroskopische Signalprogrammanpassung oder Signalprogrammbildung ist per Definition nicht möglich (vgl. auch Abbildung 2.6), wohl aber eine zeitplanabhängige Signalprogrammauswahl. Somit sind festzeitgesteuerte Lichtsignalanlagen durchaus in der Lage, unterschiedliche Belastungszustände anhand von verschiedenen Signalprogrammen abzubilden. Art und Umfang der Schaltzeitanpassung von verkehrsabhängigen Lichtsignalanlagen ist abhängig vom gewählten Steuerungsverfahren. Eine Übersicht über diese ist in Abbildung 2.6 dargestellt. Es wird dabei zwischen makroskopischen und mikroskopischen Steuerungsverfahren unterschieden. Entsprechend der Namensgebung reagieren makroskopische Steuerungsverfahren auf langfristige Entwicklungen, während mikroskopische Steuerungsverfahren kurzfristigen Einflüssen gerecht werden müssen.

Makroskopische Steuerungsverfahren: Die Regelungen, nach denen Freigabezeitverlängerungen oder Verkürzungen erfolgen dürfen, sind in den Signalprogrammen verankert, die auf makroskopischer Ebene bestimmt werden. Grundlage für deren Definition bildet eine vorherige Verkehrserhebung. Al-

| | | Steuerungsverfahren | | Ordnungszahl | Aktivierung | | verkehrsabhängig veränderbare Elemente der Signalprogramme | | | | |
|-----------------------------------|-------------------------------|--|--|--|------------------|---|--|-------------|--------------|----------------|-------------|
| | | Oberbegriff | Hauptmerkmal der Veränderbarkeit der Signalprogramme | | zeitplanabhängig | verkehrsabhängig | Umlaufzeit | Phasenfolge | Phasenanzahl | Freigabezeiten | Versatzzeit |
| A. Makroskopische Steuerungsebene | Signalprogramm-auswahl | zeitplanabhängige Auswahl der Signalprogramme | A1 | X | | in Kombination mit einem Steuerungsverfahren der Gruppe B veränderbare Elemente des Signalprogramms | | | | | |
| | | verkehrsabhängige Auswahl der Signalprogramme | A2 | | X | | | | | | |
| | Bildung Rahmen-signalprogramm | verkehrsabhängige Bildung der Rahmen-signalprogramme | A3 | | X | | | | | | |
| B. Mikroskopische Steuerungsebene | Festzeitsignalprogramm | | B1 | Aktivierung gemäß Steuerungsverfahren der Gruppe A | | | | | | | |
| | Signalprogramm-anpassung | Freigabezeit-anpassung | B2 | | | | | | X | | |
| | | Phasentausch | B3 | | | | X | | | | |
| | | Phasen-anforderung | B4 | | | | | X | X | | |
| | | Versatzzeit-anpassung | B5 | | | | | | | X | |
| | Signalprogramm-bildung | freie Veränderbarkeit | B6 | | | X | X | X | X | X | |

Abbildung 2.6: Übersicht über die Steuerungsverfahren für Lichtsignalanlagen nach RiLSA [25].

ternativ ist die Bildung eines Rahmensignalprogrammes denkbar. Dabei wird nicht aus einer Reihe von verfügbaren Programmen ausgewählt, sondern ein neues Rahmenprogramm auf Basis aktueller Messwerte gebildet. Bei den Signalprogrammen unterscheidet RiLSA zwischen zeitplanabhängiger und verkehrsabhängiger Auswahl der Signalprogramme. Bei den *zeitplanabhängigen* Signalprogrammen werden Signalprogramme entsprechend dem Kalendertag und der Uhrzeit gewählt und kommen somit bevorzugt dann zum Einsatz, wenn die Belastungsverteilung als stabil angesehen werden kann. Bei der *verkehrsabhängigen* Auswahl des Signalprogrammes sollen Programme dynamisch je nach Verkehrslage gewählt werden. Dabei wird auf Referenzmesswerte zurückgegriffen und die derzeitige Verkehrssituation mit diesen Werten abgeglichen. So können Schwellwerte definiert werden, bei deren Überschreiten ein Programmwechsel ausgelöst wird.

Mikroskopische Steuerungsverfahren:

Signalprogramm-anpassung: Bei der Signalprogramm-anpassung wird auf die Signalprogrammelemente Phasenzahl, Phasenfolge, Freigabezeit, sowie Versatzzeitanpassung eingewirkt. Die Umlaufzeit des Rahmenprogrammes bleibt dabei jedoch konstant.

Signalprogramm-bildung: Alle Signalprogrammelemente können entsprechend der aktuellen Verkehrslage mithilfe der Signalprogramm-bildung angepasst werden. Insbesondere ist keine feste Umlaufzeit vorhanden. Da es keine Festlegungen der Phasen mehr gibt, müssen einzelne Phasen bei Bedarf Frei-

gabezeiten anfordern. Aus diesem Grund ist zur Steuerung des Knotens eine feste Phasenzahl, minimale und maximale Dauer von Freigabezeiten, sowie eine Priorisierung von Phasen nötig.

Steuerungswerkzeuge: In welcher Form insbesondere bei mikroskopischen Steuerungsverfahren die Steuerung einer Lichtsignalanlage modifiziert werden soll, wird durch Steuerungswerkzeuge definiert [30]. Mittels dieser Steuerungswerkzeuge können Modelle und Strategien konzeptioniert werden, die hinsichtlich der Verkehrssituation optimierte Steuerungsverfahren ermöglichen. Man unterscheidet üblicherweise zwischen *messwertbasierten* und *modellasierten Steuerungswerkzeugen*.

Messwertbasierte Steuerungsverfahren: Dabei handelt es sich um die ursprüngliche, ältere Version der Steuerungsverfahren. Aufgrund der relativ einfachen und unkomplizierten Konzipierung ist dieses Verfahren immer noch weit verbreitet. Es berücksichtigt mittels Messung erhobene Kriterien der derzeitigen Verkehrssituation. Dabei werden ausschließlich detektierte Messwerte zur Anpassung des Steuerungsverfahrens eingesetzt und es wird keine Optimierung der Steuerungsparameter (z.B. durch Langzeitanalysen) durchgeführt [30].

Modellbasierte Steuerungsverfahren: Modellbasierte Steuerungsverfahren verfügen über Modelle zur Optimierung der Lichtsignalanlagen-Schaltung hinsichtlich der derzeitigen Verkehrslage. In der Regel wird zunächst ein Verkehrsmodell konzipiert und darauf aufbauend ein Modell zur optimalen Abarbeitung des Verkehrsaufkommens erarbeitet. Hier werden z.B. Verfahren zur Pulk- und Warteschlangenauflösung eingesetzt.

2.3.3.4 Traffic Control System Handbook

Steuerungsverfahren, die in den USA zum Einsatz kommen, sind in der Anleitung zu Lichtsignalanlagen der Federal Highway Administration spezifiziert [31]. Ein Leitfaden zur Konzeption von Verkehrskontrollsystem wurde von Gordon und Tighe veröffentlicht [32]. Auch im US-Amerikanischen Raum wird zwischen Festzeitsteuerungsverfahren und verkehrsabhängigen Steuerungsverfahren unterschieden. Die verkehrsabhängigen Steuerungsverfahren werden weiter unterteilt in teilweise verkehrsabhängige Lichtsignalanlagen („semi-actuated“), voll verkehrsabhängige Lichtsignalanlagen („fully-actuated“) und koordinierte Lichtsignalanlagen („coordinated“) [31]. Abbildung 2.7 illustriert einen Auszug der Spezifikation von Steuerungsverfahren für Lichtsignalanlagen. Dort sind auch Einsatzbereiche und Anwendungsszenarien der individuellen Steuerungsverfahren beschrieben. Ähnlich den deutschen Steuerungsverfahren gibt es bei den verkehrsabhängigen Systemen die Möglichkeit, mithilfe von Detektoren Freigabe- und Sperrzeiten entsprechend des aktuellen Belegungsgrades anzupassen. Bei den teilweise verkehrsabhängigen Lichtsignalanlagen könnte sich diese Funktion auf Nebenrichtungen beschränken, die bei Bedarf zugeschaltet werden, während die Hauptrichtungen festzeitgesteuert sind. Signalprogramm Anpassungen auf makroskopischer Ebene, in Verbindung mit Freigabezeiten-

| Programmtyp | Festzeitgesteuert | | Verkehrsabhängig | | |
|------------------------------------|---|---|---|--|---|
| | Isoliert | Koordiniert | Halb verkehrsabhängig | Voll verkehrsabhängig | Koordiniert |
| Feste Umlaufzeit | Ja | Ja | Nein | Nein | Ja |
| Bedingungen für den Einsatz | Wo Detektorinformationen nicht verfügbar sind | Wo der Verkehr konstant ist, bei nah aneinander liegenden Kreuzungen | Wo ein Standardprogramm für einen Fahrverkehr wünschenswert ist, die Hauptstraße eine Maximalgeschwindigkeit von <40 mph aufweist, bei geringer Verkehrsbelastung | Wo Detektorinformationen an allen Fahrverkehren vorliegen, vereinzelt Stellen mit einer Mindestgeschwindigkeit >40 mph | Hauptverkehrsadern mit hohem Verkehrsaufkommen und angrenzende Kreuzungen |
| Anwendungsbeispiel | Arbeitszonen | Geschäftsviertel | Autobahnen | keine angrenzenden Kreuzungen; ländlich, Schnellstraßen; Kreuzung zweier Hauptverkehrsadern | Vororte |
| Nutzen | kurzfristiger Einsatz, operational | Vorhersagbarer Betrieb, geringe Ausstattungs- und Instandhaltungskosten | geringere Kosten bei Autobahninstandhaltung | Anpassung an Verkehrsmuster, effiziente Vergabe von Grünzeiten, geringere Wartezeiten, höhere Sicherheit | geringere Wartezeiten an Hauptstraßen, je nach System Reduktion der Wartezeiten |

Abbildung 2.7: Steuerungsverfahren und Einsatzszenarien in den USA. Quelle: Federal Highway Administration des US Department of Transportation [31].

passungen, Änderung von Phasenfolgen und Umlaufzeitanpassung sind ebenfalls möglich (sowohl für festzeitgesteuerte und verkehrsabhängige Lichtsignalanlagen).

2.3.4 Potentiale für Ampelassistentenfunktionen in Europa und den USA

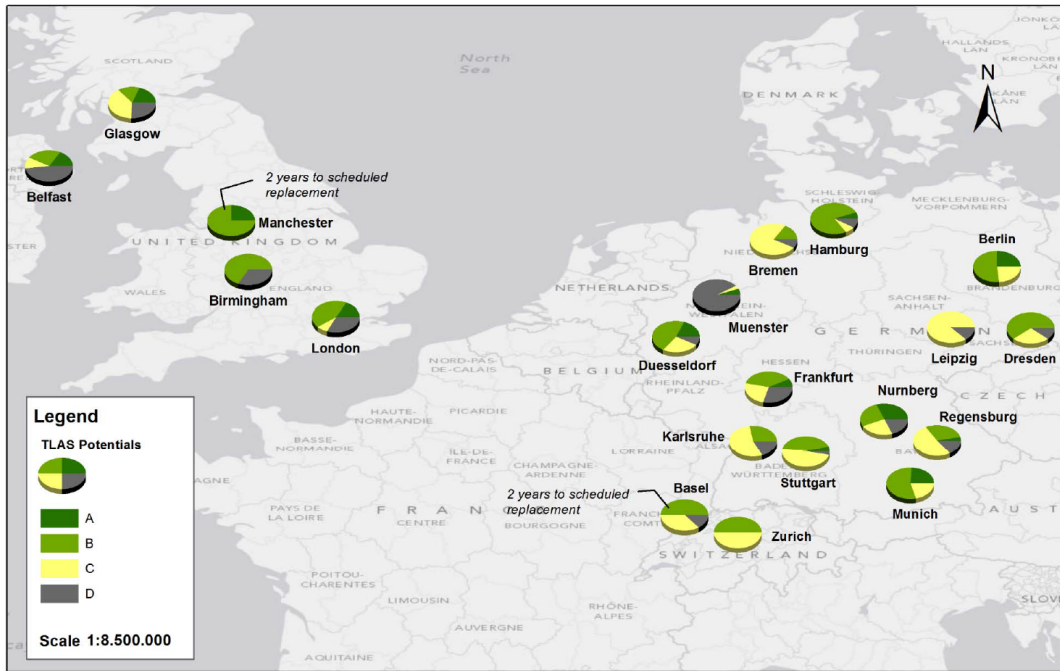
Wie sich zeigte, sind Lichtsignalanlagen teilweise mit verkehrsabhängigen Steuerungssystemen ausgestattet, die ihre Freigabe- und Sperrzeiten auf die aktuelle Verkehrssituation anpassen. Dabei kann der Grad der Verkehrsabhängigkeit stark variieren. Wie massiv sich die Steuerung auf die aktuelle Verkehrslage einstellt, ist dabei abhängig vom verwendeten Steuerungsverfahren und den zulässigen (länderspezifischen) Vorgaben (etwa SCATS, SCOOTs, RiLSA und weitere, Abschnitt 2.3), sowie der individuellen Konzeption durch die Verkehrsplaner. Darüber hinaus können städtische Verkehrszentralen ihre Anlagen individuell parametrisieren. Je adaptiver das Verkehrssteuerungssystem ist, desto schwieriger wird eine qualitativ hochwertige Prognose der zukünftigen Signalzustände. Es stellt sich daher die Frage, in welchen Ballungszentren

eine Schaltzeitprognose prinzipiell realisierbar ist. Aus diesem Grund wurde eine Arbeit vergeben, welche sich mit der Untersuchung dieser Fragestellung beschäftigte. Hierzu führte Stamatakis im Rahmen seiner Masterarbeit eine Befragung von 30 Städten durch und wertete darüber hinaus vorangegangene Befragungen aus [33]. Mit der Umfrage sollte die Lernbarkeit von Signalzuständen auf Basis zweier unterschiedlicher Verfahren beantwortet werden: Einerseits sollte beantwortet werden, ob Echtzeitinformationen über Signalzustände und Umlaufzeit prinzipiell technisch zur Verfügung gestellt werden können. Derartige Datensätze sollen als Eingangsquelle für Prognosealgorithmen dienen. Auf der anderen Seite sollte beantwortet werden, wie hoch der Anteil von festzeitgesteuerten und schwach verkehrsabhängigen Lichtsignalanlagen ist. Die Parameter dieser Lichtsignalanlagen könnten mithilfe anderer Quellen, etwa durch Auswertung von Fahrtverläufen von Fahrzeugen, gelernt werden.

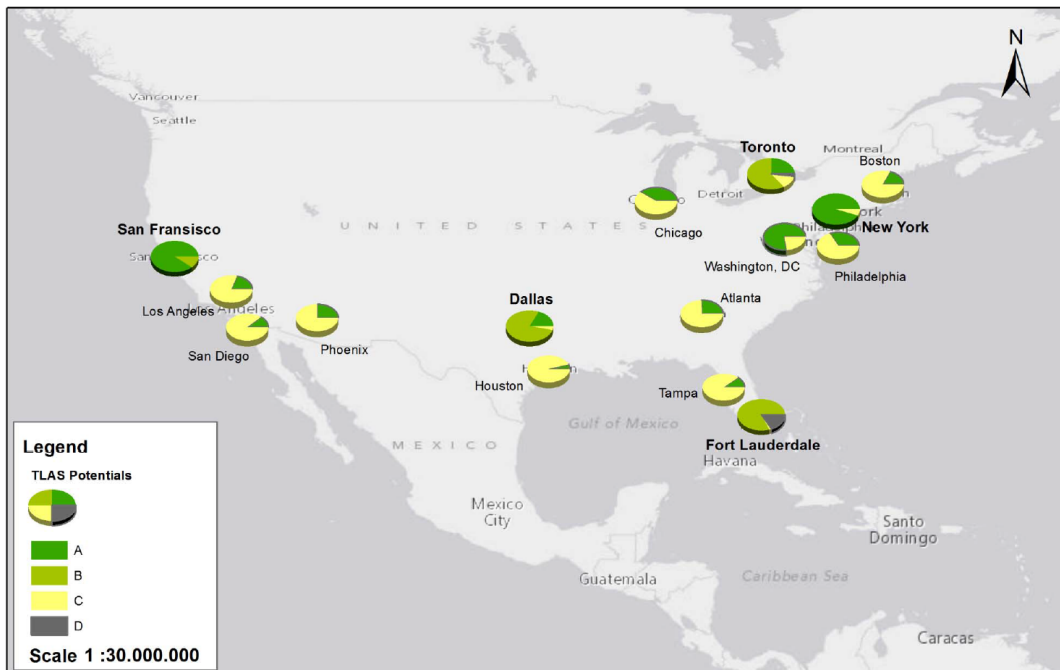
Auf Basis der erhaltenen Informationen ordnete Stamatakis die Steuerungsverfahren vier Kategorien zu:

- **Kategorie A:** In diese Kategorie fallen alle Lichtsignalanlagen, für die alle Ampelassistentenzfunktionen mit hoher Wahrscheinlichkeit realisierbar sind. Diese Lichtsignalanlagen zeichnen sich durch vordefinierte und unveränderliche Parameter aus (festzeitgesteuerte Lichtsignalanlagen).
- **Kategorie B:** Diese Kategorie umfasst alle Lichtsignalanlagen, für welche die Funktionen Restrotanzeige und Grüne-Welle-Routing mit hoher Wahrscheinlichkeit realisierbar sind. Diese umfassen festzeitgesteuerte Lichtsignalanlagen mit gelegentlichen Modifikationen und schwach verkehrsabhängige Lichtsignalanlagen.
- **Kategorie C:** Alle Lichtsignalanlagen mit verkehrsabhängigen Steuerungsverfahren und/oder ÖPNV-Priorisierung, sowie modellbasierte Kontrollsysteme fallen in diese Kategorie. Für Lichtsignalanlagen dieser Kategorie ist nicht eindeutig bestimmbar, ob sie prognostizierbar sind. Dies hängt stark von der Verfügbarkeit von Schaltzeitinformationen und Latenz, sowie individueller Systemausprägung durch die Verkehrszentrale ab und muss für jeden Fall einzeln betrachtet werden.
- **Kategorie D:** In diese Kategorie fallen alle Lichtsignalanlagen, die nicht mit einer Verkehrszentrale verbunden sind und daher keine Aussage möglich ist. Auch konnte für diese nicht eruiert werden, ob sie in festzeitgesteuerten oder verkehrsabhängigen Modi laufen.

Abbildungen 2.8a und 2.8b zeigen die Potentiale von Ampelassistentenzfunktionen für untersuchte Städte auf. Für weiterführende Details zu den Kennzahlen sei auf die Arbeit von Stamatakis [33] verwiesen. Insgesamt kann das Potential für Ampelassistentenzfunktion ausgehend von der aktuellen Infrastrukturlage aus Städtensicht als hoch angesehen werden. Ferner ist vor dem Hintergrund vieler



(a) Europa.



(b) USA.

Abbildung 2.8: Potentiale der Ampelassistentenfunktionen in untersuchten Städten (Europa und USA) [33].

stadtseitiger Bestrebungen in Richtung einer „Smart City“ eine Erleichterung der Akquise und Verarbeitung aus Providersicht von Schaltzeitprognosen nicht unwahrscheinlich.

2.4 Floating Car Data

Als einer der Haupttreiber der Technologie Floating Car Data (FCD) gilt die Erfassung der aktuellen Verkehrssituation. Um die Aktualität dieser zu verbessern, werden seit Ende des letzten Jahrhunderts auch Fahrzeuge als Informationsquellen herangezogen [34], [35, Kapitel 2]. Hierzu werden Daten im Fahrzeug erhoben (etwa Position und Zeitstempel) und diese an ein Backend gesendet. Auch eine (räumliche) Trajektorie (*engl. spatial trajectory*) speichert diese Information, beschränkt sich jedoch nicht auf Fahrzeugdaten.

2.4.1 Begriffliche Abgrenzung und Aufbau

Bei der FCD-Technologie wird in der Literatur oft der Aspekt der Kommunikation mit Dritten (Car-to-X) hervorgehoben. In der Definition von IT-Wissen.info wird die FCD-Technologie als „ein Telematikdienst, (...) in der Fahrzeuge als mobile Erfassungseinheiten für die Ermittlung von Verkehrsdaten benutzt werden“, beschrieben. „Das Kraftfahrzeug selbst kann als mobiles Telematik-System betrachtet werden, das die Daten über die Position und den Verkehrszustand über Mobilfunknetze an die Leitzentrale oder bei der Car-to-Car-Kommunikation (C2C) an andere Fahrzeuge übermittelt.“ [36] Geprägt ist der Ausdruck durch die Analogie des Fahrzeuges als „mitschwimmender“ Sensor. Eine Erweiterung der FCD-Technologie wird unter dem Begriff Extended Floating Car Data (XFCD) geführt. Hiermit sollen neue Dienste durch die Erfassung zusätzlicher Informationen ermöglicht werden [34, 35, 36]. Mit der zunehmenden Verbreitung von Smartphones hat sich in Anlehnung an FCD der Begriff Floating Phone Data (FPD) etabliert. Hierbei werden Smartphone-Positionen geloggt und übermittelt. Diese sind unter Umständen ungenauer als FCD, da nicht immer GPS-Informationen zur Verfügung stehen und so nur eine funkzellengenaue Ortung möglich ist. FPD sind insbesondere bei der Verkehrsflussbestimmung eine gute Ergänzung zu FCD [37].

Die Abgrenzung zum Begriff (räumliche) Trajektorie ist nicht ganz einfach. Ji-wai Han [38] definiert sie sinngemäß als eine Spur, welche durch ein sich bewegendes Objekt im geographischen Raum erzeugt wird. Üblicherweise ist sie repräsentiert als eine Serie von chronologisch geordneten Punkten $p_1 \rightarrow p_2 \rightarrow p_n$, wobei ein jeder Punkt aus einer Menge geospatialer Koordinaten und einem Zeitstempel besteht, also $p = (x, y, t)$. Als Beispiele werden Fahrzeuge genauso wie Personen, Tiere oder natürliche Phänomene angeführt. Eine Erweiterung der Trajektorie um zusätzliche Informationen wie bei XFCD ist in dieser Definition nicht vorgesehen; sie beschränkt sich auf die Informationen aus Geo-Koordinaten und Zeitstempel. Ferner gibt es bei der Definition der Trajektorie keine Beschreibung des Kommunikationsmediums. Es wird hier viel allgemeiner von „gesammelten Bewegungsdaten“ gesprochen [38]. FCD dagegen werden in der Literatur häufig in Verbindung zur direkten Car-to-X-Kommunikation gebracht. So wird oftmals die Übermittlung der Daten in der Definition mit beschrieben. Insbesondere werden die Mobilfunkkanäle als Übertragungsmedi-

en angegeben [36, 39]. Folglich kann die FCD-Technologie als eine Unterform der Trajektorie betrachtet werden. In dieser Arbeit wird unter anderem mit FCD entsprechend der hier beschriebenen Definition gearbeitet, die im weiteren Verlauf dieser Arbeit auch unter diesem Begriff geführt werden.

2.4.2 Charakteristika von Floating Car Data

Insbesondere für die Erforschung und Entwicklung neuer Verfahren, wie etwa die Rekonstruktion von Signalzuständen an Lichtsignalanlagen ist es notwendig, hinreichende Kenntnisse über die derzeitigen und in Zukunft zu erwartenden Charakteristika von FCD zu haben. So ist es vor allem von Interesse, Faktoren wie Samplingraten, aber auch die zeitliche Verteilung von FCD zu kennen. FCD haben typischerweise unterschiedliche Ausprägungen, die sich eng an die entsprechenden Use Cases orientieren. Für viele Szenarien ist die Übermittlung bloßer Positions- und Zeitstempel nicht ausreichend. Aus diesem Grunde gibt es die schon zuvor angesprochene Erweiterung von FCD um zusätzlich Informationen, die von Interesse sein könnten. Man spricht hier von Extended FCD. Prinzipiell ist der Art und Fülle an Informationen, die übersendet werden sollen, keine Grenze gesetzt. Es können etwa Fahrbahnzustand und Fahrerverhalten ausgewertet und übermittelt werden, um z.B. lokale Gefahrenwarnungen zu ermöglichen. Ferner können Schilder über verbaute Kamerasysteme erkannt werden und so der Flotte zur Verfügung gestellt werden. Ein weiteres zukünftiges Szenario ist auch die Ampelerkennung und Projizierung des derzeitigen Zustandes im Fahrzeug mit der Kamera. Eine Übermittlung dieser speziellen Information könnte die Rekonstruktion und Prognose zukünftiger Schaltzeiten an Lichtsignalanlagen weiter unterstützen. Leider ist eine Erkennung und insbesondere deren Rückübermittlung via XFCD-Technologie in naher Zukunft noch nicht zu erwarten.

Die FCD-Technologie ist hingegen technisch schon weit fortgeschritten. So haben die meisten neueren Modelle die technische Möglichkeit, FCD zu sammeln und zu übermitteln. Im Rahmen der vorliegenden Arbeit darf auf Testflottendaten von BMW-Testfahrzeugen zugegriffen werden. Insgesamt stehen mehrere hunderttausend aufgezeichnete Fahrten von Testfahrzeugen in einem Beobachtungszeitraum von etwa einem Jahr zur Verfügung. Die BMW Group ist nicht das einzige Unternehmen, das den Weg einschlägt, mithilfe von aggregierten Flotteninformationen neue Dienste zu schaffen. So sammeln weitere Unternehmen und Forschungseinrichtungen Daten, um diese für Forschungszwecke zu nutzen, aber auch um neue Dienste anbieten zu können. Der am weitesten verbreitete Dienst ist die Bereitstellung von Echtzeitverkehrsinformationen. Hierzu erfassen proprietäre Anbieter bereits große Mengen an FCD. HERE verarbeitet 80.000 Datenquellen täglich [40], INRIX aggregiert Daten von über 200 Großkunden und Industriepartnern (etwa Ford, Microsoft, BMW) [41], aber auch von Smartphones [42], TomTom sammelt umfassende Daten der Fahrverläufe ihrer Kunden [43]. Überdies werden auch Positionsdaten von

Smartphones erfasst und ausgewertet. Airsage erfasst grobe Positionsdaten von Mobiltelefonen durch Auswertung ihrer Verbindungen zu Funkzellen [44]. WAZE wertet wie Google Live Traffic GPS-Positionen, WLAN-Hotspots und Funkzellenverbindungen aus, um Positionen von Smartphonebesitzern zu tracken [45, 46]. Viele Bus- und Taxiunternehmen haben GPS-Tracking und Logging zur Generierung von FCD fest verbaut und sind so in der Lage, zeitliche und räumliche „Hotspots“ zu erfassen und sich so auf Kundenwünsche und Nachfrageverhalten besser einzustellen. Nur einige Beispiele sind hier NextBus [47] Taxi Stockholm[48], Taxi Dresden [49] oder YellowCabSF i.V.m. Cabspotting [50]. Während aufgezeichnete Datensätze für verschiedenste Untersuchungen verwendet und deren Ergebnisse veröffentlicht wurden, hat die Forschungsgemeinschaft in der Regel keinen Zugriff auf diese Quellen. Meist handelt es sich hier um proprietäre Daten, die nicht kostenlos zur Verfügung gestellt werden, oder aus datenschutzrechtlichen Gründen nicht veröffentlicht werden dürfen. Es werden im Folgenden, ohne Anspruch auf Vollständigkeit, einige in der Literatur häufig referenzierte Datensätze aufgelistet und hinsichtlich ihrer Eigenschaften verglichen. In Tabelle 2.1 sind diese dargestellt.

| | Abdeckung | Samplingrate | Anzahl Sender | Datenquellen |
|---------------------|---------------------------------------|---|---|--|
| TomTom | >20 Länder in Europa, USA, ZA, AUS | Richtungs-/ Geschwindigkeitsänderung [43] | ca. 36 Mio. Vodafone Mobilfunkgeräte + TomTom LIVE Geräte | TomTom Live Navigationsgeräte, Smartphones mit TomTom App, Daimler |
| BMW Testflotte | MUC, BER, HAM | Richtungs-/ Geschwindigkeitsänderung | 500 | Testfahrzeuge |
| INRIX | >30 Länder in Europa, US, RU, CHN, AF | unbekannt | 80.000 [40] | 200 Großkunden, Privatkunden |
| Google Live Traffic | >20 Länder in Europa, USA, CDN | 1Sek-1Min[46] | unbekannt | Android-Nutzer |
| Waze | >20 Länder in Europa, USA, AUS, CDN | 1Sek-1Min [46] | 50 Millionen [40] (Stand 2013) | Android-Nutzer |
| NextBus | SF | minütlich | unbekannt | NextBus |
| Yellow-cabSF | SF | minütlich | ca 800-900 | YellowCab |

Tabelle 2.1: Vergleich ausgewählter FCD-Datenquellen aus dem Fahrezugumfeld.

Im Vergleich der einzelnen Datensätze fällt auf, dass insbesondere die Samplingrate variiert. Für NextBus und YellowCabSF, die Daten insbesondere zur Erkennung von Nachfragespitzen und wichtigen Orten nutzen, ist eine minütliche Aufzeichnung ausreichend. TomTom Daten und BWM-Testflottendaten

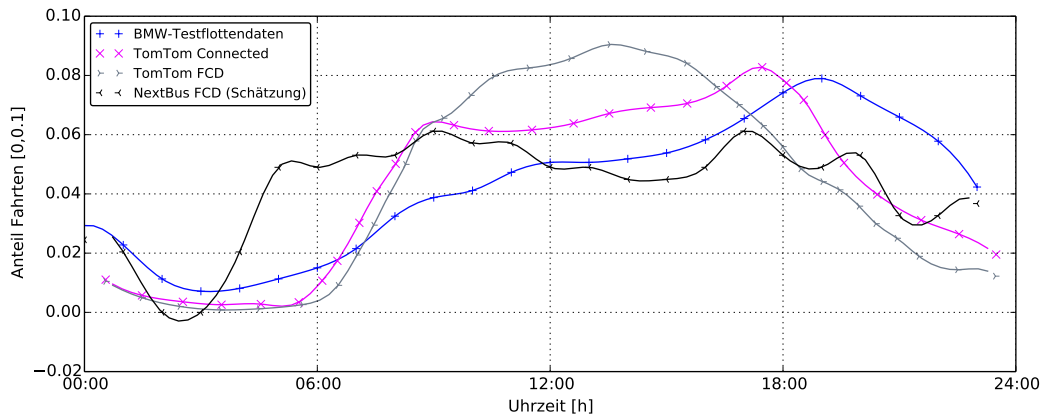


Abbildung 2.9: TomTom FCD, BMW-Testflottendaten und NextBus FCD: Anteil von Fahrten in Abhängigkeit von der Tageszeit. Die Verteilung der TomTom Daten ist aus [43] entnommen. Die Verteilung der NextBus FCD wurde mithilfe der von Fayazi et al. von rekonstruierten Stopzeiten [51] geschätzt.

besitzen die größte Genauigkeit; der zugrundeliegende Algorithmus setzt Positionspunkte bei jeder Richtungs- bzw. Geschwindigkeitsveränderung. Die Datensätze dienen insbesondere der Erforschung neuer Technologien. Google Live Traffic und Waze scheinen ähnliche Samplingraten aufzuweisen. Die Samplingraten der Quelldaten von INRIX dagegen sind unbekannt. Allgemein ist jedoch ein Trend hin zu Aufnahmen mit hoher Samplingrate zu beobachten, da diese einen deutlich größeren Informationsgehalt aufweisen. Für viele Einsatzszenarien ist diese Informationsdichte in einzelnen FCD auch unabdingbar. Zur Erstellung von hoch-präzisen Karten wird diese genauso benötigt wie für Ampelassistentenfunktionen. Im späteren Verlauf der Arbeit vorgestellte Verfahren werden in Folge dessen von einer hohen Samplingrate bei Richtungs- oder Geschwindigkeitsänderung ausgehen.

Hinsichtlich der Charakteristika von FCD ist die zeitliche Verteilung von vorliegenden Aufnahmen ebenso von Relevanz. Insbesondere um zeitliche Ereignisse aus FCD zu extrahieren, wäre eine gleichmäßige Verteilung von Daten wünschenswert. Es sei an dieser Stelle auf Abschnitt 4.2.2 verwiesen, in dem auf diese Problematik noch einmal vertiefend eingegangen wird. Für die genauere Untersuchung der zeitlichen Verteilung der FCD können Datensätze von TomTom, NextBus und der BMW-Testflotte herangezogen werden. Die zeitliche Verteilung der TomTom-FCD wurde 2012 von Nick Cohn and Hugo Bischoff untersucht [43]. Die Verteilung der NextBus-Flottendaten kann auf Basis der von Fayazi vorgestellten Verfahren zur Schaltzeitrekonstruktion [51] geschätzt werden. Abbildung 2.9 stellt für TomTom FCD, BMW-Testflottendaten und NextBus FCD den Anteil von Fahrten in Abhängigkeit von der Tageszeit dar. Bei den BMW-Testflottendaten ist die Spitze der aufgezeichneten Daten in den Abendstunden um 19:00 Uhr erreicht. Die Fahrer nutzten diese Fahr-

zeuge offensichtlich besonders nach den Bürozeiten. Allgemein werden diese Fahrzeuge deutlich häufiger nach Feierabend benutzt als in den übrigen Tagesstunden. TomTom Connected Daten weisen zwei Spitzen zu den beiden Hauptverkehrszeiten auf. Besonders viele Fahrten werden um 9:00 Uhr und 17:00 Uhr getätigt. Auffällig ist, dass der Anteil an Fahrten zwischen 9:00 Uhr und 17:00 nicht signifikant abfällt. Bei TomTom FCD ist die Spitze gar in der frühen Nachmittagszeit erreicht. Gleichzeitig ist der Anteil der Fahrten viel breiter auf die Bürozeiten verteilt als in den anderen beiden Datenätzen. Die NextBus Aufzeichnung weisen die gleichmäßigste Verteilung der Fahrten über den gesamten Tag auf. Es zeichnen sich nur leichte Spitzen zu den Hauptverkehrszeiten ab. Dies ist ganz offensichtlich einem gleichmäßigem Fahrplan geschuldet. Welche Gestalt die zeitliche Verteilung von FCD hat, ist abhängig von der zugrunde liegenden Nutzergruppe. Während Linienbusse einem festen Fahrplan folgen und aus Servicegründen auch in Schwachverkehrszeiten verkehren, sind die Nutzungszeiten von Privat- und Dienstfahrzeugen extremen Schwankungen unterworfen. Dies spiegelt sich in einer sehr ungleichmäßigen Verteilung von Fahrtanteilen im Tagesverlauf wider.

2.4.3 Potential und Risiken von (X)FCD

Aus der Sammlung und Verarbeitung nutzerbezogener Daten wie FCD ergeben sich große Chancen und neue Einsatzgebiete, aber auch Risiken. Fahrer fordern Innovationen im Fahrzeug, wie etwa Grünband-Geschwindigkeitsempfehlungen, Echtzeitverkehrsinformationen, lokale Gefahrenwarnungen. Um diese Assistenzfunktionen zu realisieren, müssen jedoch im Umkehrschluss die Fahrten der Kunden aufgezeichnet und ausgewertet werden. Jedoch nicht jeder Fahrer fühlt sich wohl bei dem Gedanken, diese Informationen preiszugeben. Zu schnell ergeben sich Einfallstore für den Datenmissbrauch, etwa das Anlegen von Bewegungsprofilen von Fahrern. So können leicht Wohn- und Arbeitsorte, oder Gewohnheiten rekonstruiert werden. Aus Unternehmenssicht muss also sichergestellt werden, dass die gesammelten Daten (Einverständnis des Kunden vorausgesetzt) hinreichend anonymisiert sind, um die Möglichkeiten zum Missbrauch zu minimieren.

Ogleich mit (X)FCD eine beeindruckende Palette an innovativen Funktionen ermöglicht wird, ist deren Erhebung datenschutzrechtlich dennoch hochbrisant. Es sollte aus Unternehmenssicht sichergestellt werden, dass diese hochsensiblen Daten hinreichend geschützt und anonymisiert sind, um Missbrauch vorzubeugen.

2.5 Straßennetze als Graphen

Im Folgenden werden die Grundlagen der Graphentheorie gelegt, welche für Routingverfahren in Straßennetzen benötigt werden.

Straßennetze werden als gerichtete Graphen $G = (V, E)$ mit einer Menge V von Knoten und einer Menge E von Kanten repräsentiert. Jede Kante $(u, v) \in E$ mit $u, v \in V$ besitzt ein ihr zugeordnetes nicht negatives Gewicht $w(e) = w(u, v) \in \mathbb{R}^+$, was die Kosten einer jeweiligen Kante repräsentiert. Die Kreuzungspunkte einer Karte bilden dabei die Knoten des Graphen, während die Kanten Straßenabschnitte repräsentieren. Eine Gewichtung kann dabei die Länge, durchschnittliche Reisezeit, Energieverbrauch, Maut oder andere Faktoren darstellen.

2.5.1 Routingverfahren in Straßennetzen

Für die Berechnung von Routen in Straßennetzen ist die Lösung des kürzeste Wege Problems zweier Punkte nötig. Beim kürzeste Wege Problem ist der kürzeste Pfad vom Startknoten $s \in V$ zum Endknoten $e \in V$ gesucht. Die Gewichtungsfunktion muss dabei minimal sein.

2.5.2 Basisalgorithmen für Routingverfahren

Zur Lösung des kürzeste Wege Problems gibt es in der Literatur einige fest etablierte Standardverfahren. Im Folgenden werden die für die Navigation gebräuchlichsten Ansätze vorgestellt.

2.5.2.1 Algorithmus von Dijkstra

Gängige Routingverfahren bauen auf die Standardlösung des kürzeste Wege Problem auf, dem Algorithmus von Dijkstra. Der Algorithmus, der bereits 1959 veröffentlicht wurde, ist ein Suchverfahren in Graphen, das das kürzeste Wege Problem unter Einbeziehung von Kantengewichten löst [52]. Hierbei werden alle Knoten $v \in V$ eines zu untersuchenden Graphen G in eine geordnete Liste Q eingetragen. Die Knoten werden nach ihren Kosten des gewählten Maßes (etwa Länge, Reisezeit o.ä.) zum Startknoten geordnet. Initial sind die Kosten unendlich. Im Folgenden wird mit jedem Iterationsschritt der jeweilige Knoten v mit den geringsten Kosten zum zu untersuchenden Knoten s aus der Liste Q expandiert. Die jeweiligen Kosten werden dabei aus der Gewichtungsfunktion $w(u, v)$ bestimmt; $g(s, v) = g(s, u) + w(u, v)$. Ist der Kostenwert kleiner als ein zuvor berechneter, so wird v mit $g(s, v)$ in die Warteschlange Q eingefügt. Wurden alle Nachbarn von s untersucht, wird dieser aus Q entfernt. Für die Rekonstruktion des kürzesten Pfades wird Knoten u als Vorgängerknoten von v gespeichert. Dieser Prozess wird solange sukzessive wiederholt, bis der Zielknoten z als Knoten mit den geringsten Kosten identifiziert ist.

2.5.2.2 A*-Algorithmus

Der A*-Algorithmus, erstmals 1968 von Hart et al. [53] vorgestellt, gilt allgemein als Erweiterung des Algorithmus von Dijkstra. Aufbauend zum Algorithmus

mus von Dijkstra wird hierbei eine Schätzfunktion (Heuristik) $h : V \rightarrow \mathbb{R}$ verwendet, mit der die Kosten eines jeden Knoten zum Zielknoten geschätzt werden. Es wird nunmehr ein Knoten $v \in V$ nicht mehr ausschließlich über seine Kosten geordnet, sondern über seine Priorität, bestehend aus $g(s, u) + h(u, v)$. Allgemein wird die Priorität als *f-Wert* bezeichnet, $h(u, v)$ der *h-Wert* genannt. Für einen Knoten u stellt $g(s, u)$ die Kosten dar, um vom Startknoten s zu Knoten u zu gelangen. Die geschätzten Kosten von Knoten u bis zum Zielknoten v werden durch $h(u, v)$ beschrieben. Im Vergleich zum Algorithmus von Dijkstra entsteht mithilfe der Schätzfunktion $h(u, v)$ auf den f-Wert eines Knoten die Möglichkeit einer zielgerichteten Suche, die die Knoten bevorzugt, deren Kosten zum Ziel gering geschätzt werden. Eine gewählte Heuristik (etwa Luftlinie) ist dabei optimal, wenn diese *monoton* ist. Hierzu dürfen Kosten nie überschätzt werden; für jeden Knoten müssen die geschätzten Kosten zum Ziel kleiner oder gleich den tatsächlichen Kosten sein. Ferner dürfen die geschätzten Kosten eines Knoten k nicht größer sein als die tatsächlichen Kosten zu seinem Nachfolgerknoten zuzüglich dessen geschätzten Kosten. Im Kontext der Routenberechnung ist die Anwendung des A*-Algorithmus aufgrund seines Performancegewinns essentiell. Je mehr dabei die geschätzten Kosten bis zum Ziel den tatsächlichen Kosten entsprechen, desto höher ist der Performancegewinn des A*-Algorithmus.

2.5.3 Routenplanung in Straßennetzen

Der alleinige Einsatz des A*-Algorithmus zur Berechnung kürzester Wege, insbesondere sehr großer Straßennetzwerke ist immer noch zu rechenintensiv. Problematisch dabei ist insbesondere, dass in klassischen Ansätzen zur Routenberechnung die Euklidische Distanz und die durchschnittliche Geschwindigkeit der schnellsten Route herangezogen werden müssen. Dabei handelt es sich um eine sehr konservative Schätzung. Dies ist notwendig, denn eine Überschätzung der Heuristik würde zu einem Verlust seiner Optimalität führen. Auf der anderen Seite ist somit der Performancegewinn relativ gering. Sanders et al. geben einen Geschwindigkeitsgewinn mit lediglich dem Faktor 2-3 an [54].

Aus diesem Grund gibt es eine Reihe von Maßnahmen zur Verbesserung der Berechnungszeiten von Routen. Die relevantesten werden im Folgenden vorgestellt.

2.5.3.1 Eine einfache Heuristik als Industriestandard

Im Zuge der schnellen Umsetzbarkeit wird in proprietären Routingsystemen gerne auf eine einfache Heuristik zurückgegriffen: Die A*-Suche in Verbindung mit der einfachen Regel, „unwichtige“ Straßen lediglich am Ende und am Ziel zu betrachten. Üblicherweise sind diese Informationen in Form von den Attributen *Lane Category* und *Street Category* im Kartenmaterial hinterlegt. Während dies schon lange ein weit verbreiteter Standard in der Routenberechnung

ist [55], wird in der Wissenschaft die Unmöglichkeit einer Performancegarantie für diesen Ansatz bemängelt [54]. Ferner birgt die manuelle Einordnung eine schwere Abwägung zwischen Performancegewinn und Suboptimalität des gefundenen Weges [56]. Auf der anderen Seite jedoch besticht dieser Ansatz durch minimale Änderungsanforderungen bei der Routenberechnung.

2.5.3.2 Einführung von Hierarchien

Der zuvor beschriebene Ansatz stellt bereits eine Form des hierarchischen Clusters dar. Dieser Ansatz wird mit dem Verfahren der Highway Hierarchien weiter professionalisiert [57, 58]. Mit dem Verfahren der Highway Hierarchien wird automatisiert und sukzessive ein kontrahiertes Highway Netzwerk erzeugt, das exakte kürzeste Wege bewahrt. Hierarchielevel sind dabei unabhängig von Straßentypen. Bei diesem Ansatz werden iterativ Knoten mit einem niedrigen Knotengrad kontrahiert. Ein Tuning Parameter H kontrolliert dabei den Schrumpfungsfaktor des Graphen. Hier muss jedoch auch die Routenberechnung an die Highway Hierarchien angepasst werden. Insbesondere führen Sanders et al. einige Restriktionen ein, die bei einer multilevel-Dijkstra-Berechnung berücksichtigt werden müssen [57].

Transit Node Routing [59, 60, 61] stellt einen Vertreter der sogenannten „Bounded Hop Techniques“ dar. Bei diesem Ansatz wird die Tatsache ausgenutzt, dass nur wenige Routen relevante Verbindungen für lange Reisen darstellen. Dazu werden Transitknoten und die Verbindungen zu Zugangsrouten vorberechnet. Distanzen zu den Zugangstransitknoten werden aus einer Menge von vorher definierten Transitknoten vorberechnet und in sogenannten Distance Tables gespeichert. Eine modifizierte Anfrage bestimmt nun diejenigen Zugangsknoten, welche die kombinierte Distanz der beiden Zugangsrouten zur Distance Table minimiert.

Sowohl für Highway Hierarchies, als auch Transitknoten ist der Geschwindigkeitsgewinn bei der Routenberechnung bemerkenswert, obwohl es Unterschiede in der Vorberechnungszeit gibt. Speedup-Techniken stellen derzeit noch ein Problem für das Mikroalternative Routing dar, da ausgedünnte Graphen nicht viele alternative Routen zulassen. Ein in der Industrie weit verbreiteter Ansatz dieses Problem zu lösen, ist dynamisch Teilmengen des Graphen relevanter Bereiche, dh. Gridzellen von Graphausschnitten zu laden. Eine mögliche Umsetzung wurde ebenfalls von Bast et al. vorgestellt [60]. Für das in Kapitel 5 vorgestellte Verfahren zum ampeladaptiven Routing wird von diesem Modell der Kartenrepräsentation ausgegangen und eine Gridzelle für den Raum München definiert. So kann sichergestellt werden, dass das vorgeschlagene dynamische Routingmodell einfach in bestehende Applikationen integriert werden kann.

3 Lernen von Signalzuständen mit historischen Daten

Ampelassistentenfunktionen wie die in Abschnitt 2.1.2 vorgestellten Grünband-Geschwindigkeitsempfehlung, Restrotanzeige, oder eine Prepare-to-Stop-Aussage benötigen Schätzungen zukünftiger Signalzustände. Diese zu generieren ist keine leichte Aufgabe: Wie sich in Abschnitt 2.3 zeigt, sind Lichtsignalanlagen teilweise mit verkehrsabhängigen Steuerungssystemen ausgestattet, welche ihre Freigabe- und Sperrzeiten auf die aktuelle Verkehrssituation anpassen. Dabei kann der Grad der Verkehrsabhängigkeit stark variieren. Die Untersuchung von Städten hinsichtlich der Lernbarkeit von Schaltzeiten durch Stamatakis (vgl. Abschnitt 2.3.4) zeigte jedoch für eine Vielzahl von Städten auf, dass eine Prognose der zukünftigen Schaltzeiten mithilfe von vergangenen Schaltzeitinformationen möglich sein sollte.

Im Rahmen dieses Kapitels soll der Ansatz einer vernetzten Schaltzeitprognose mittels Kommunikation zwischen Fahrzeugen und Verkehrsinfrastruktur verfolgt werden. Insbesondere soll hier der Gedanke der Vernetzung einer „Smart City“ mit dem intelligenten Fahrzeug aufgegriffen werden. Wie in Abschnitt 1.1 beschrieben wurde, sehen sich auch Städte zunehmend in der Pflicht, durch flexible Kommunikationssysteme Abläufe, wie auch das Verkehrsgeschehen, flexibler zu gestalten. Einen ersten Schritt in diese Richtung stellte das Kooperationsprojekt mit dem Kreisverwaltungsreferat München zur Schaltzeitprognose in München dar. Im Rahmen dessen wurden zyklisch aktualisierte, vergangene Schaltzeitinformationen aus dem Raum München zur Verfügung gestellt, die zur Entwicklung und Implementierung von Prognoseverfahren genutzt werden durften. Auf die entsprechende Datengrundlage wird an geeigneter Stelle (Abschnitt 3.5.1) eingegangen.

3.1 Vorveröffentlichungen

Die Kerninhalte dieses Kapitels wurden vom Autor bereits in [105] publiziert. Wie in Kapitel 1 ausführlich dargestellt, stammen die im Manuskript und nachfolgend präsentierten Inhalte bzgl. der Idee, des Konzepts, der Theorie und Evaluation vom Autor der vorliegenden Arbeit. Ebenfalls in dem Manuskript enthalten waren die Abbildungen 3.2 und 3.3. Weitere Inhalte des Kapitels wurden in [106] veröffentlicht. Auf kleinere Teilaspekte aus den Veröffentlichungen in [104], [103] und [102] wird im Rahmen dieses Kapitels ebenfalls Bezug genommen.

3.2 Verfahren zur Schaltzeitprognose mit Schaltinformationen

Es existieren verschiedene Ansätze, mit deren Hilfe die Prognose von Schaltzeiten von Lichtsignalanlagen auf Basis vergangener Schaltzeitinformationen realisiert werden soll. Generell lassen sich diese in drei Bereiche unterteilen, nämlich nicht statistische Verfahren, statistische Verfahren und hybride Ansätze [106].

Nicht statistische Verfahren: Hierbei soll die Situation an einer Lichtsignalanlage möglichst vollständig beschrieben werden. So wird der Zustand einer Lichtsignalanlage eines Verkehrsknotenpunkts durch die Verkehrskenngrößen des Knotenpunkts beschrieben, die Stellgrößen der Lichtsignalanlagen, sowie durch die aktuelle Verkehrssituation. Zu den Verkehrskenngrößen gehören insbesondere die mithilfe von Erfassungseinrichtungen (Detektoren, Taster) ermittelten Informationen. Dazu zählen der durch Detektoren gemessene Belegungsgrad, die Belegungszeit und Zeitlücken, Anwesenheitsfeststellung, Anforderung und Zählung von Fahrzeugen. Ebenfalls anzuführen sind die Bemessung der Freigabezeit, Geschwindigkeitsmessung und Anmeldung von Fußgängern und Radfahrern (vgl. Abschnitt 2.3.3).

Ebenso gehören auch modellbasierte Größen zu den Verkehrskenngrößen. So können z.B. empirisch ermittelte Reisezeiten, die Verkehrssituation (Stau, Wartezeiten) oder Verkehrsströme Einflussgrößen darstellen. Die Stellgrößen stellen die für die Lichtsignalanlage gewählten Steuerungsverfahren dar (vgl. auch Abschnitt 2.3.3). Hierzu zählen Faktoren wie Umlaufzeit, Freigabezeit, Phasenfolge oder Offset. Die Verkehrskenngrößen und Stellgrößen werden auf Grundlage der aktuellen Verkehrssituation ermittelt. Wenn Detektoren eine hohe Anzahl von Überfahrungen feststellen, können die Grünzeiten einer Lichtsignalanlage verlängert werden. Nicht statistischen Verfahren zur Prognose von Lichtsignalanlagen ermitteln alle Einflussgrößen (Verkehrssituation, Verkehrskenngrößen, Stellgrößen), um die Situation einer Lichtsignalanlage vollständig beschreiben zu können. Derartige Ansätze sind in größerem Umfang nur mit hohem Ressourcenaufwand realisierbar. Zum einen müssen Vorkehrungen getroffen werden, um die derzeitige Verkehrssituation abzubilden. Dazu gehören Verkehrsüberwachung, Messung und Prognose der derzeitigen Verkehrsstruktur. Daher müssen die Verkehrskenngrößen und Stellgrößen einer jeden zu prognostizierenden Lichtsignalanlage in Echtzeit zur Verfügung stehen. Allerdings ist die Steuerung und Verwaltung von Lichtsignalanlagen Aufgabe der Kommunen bzw. Städten, von denen die Verkehrskenngrößen bzw. Stellgrößen akquiriert werden müssen.

Neben den daraus resultierenden verhandlungstechnischen Herausforderungen ergeben sich auch technische Probleme. So ist laut Klaus Krämer, dem Verantwortlichen für das Verkehrsmanagement der Stadt München, eine Zurverfügungstellung von Detektordaten in großem Umfang technisch nicht, bzw. nur mit großem personellen Aufwand, umsetzbar.

Statistische Verfahren: Ziel dieses Ansatzes ist es, insbesondere mit Modellen mathematischer Statistik (Schätztheorie, Zeitreihenanalyse, lineare und multivariate Modelle, u.ä.), Data Mining und maschinellem Lernen, sowie numerischer Mathematik (Optimierung, Approximationsverfahren) kosten- und berechnungseffiziente Verfahren abzuleiten. Im Gegensatz zu nicht statistischen Ansätzen gelten diese Modelle von einem technischen Standpunkt aus als skalierbarer. Die Forschung in dem Bereich befindet sich noch in den Anfängen. Zwar befassten sich bereits einige Vorarbeiten mit dieser Thematik, jedoch konnte noch kein Ansatz in der Praxis einsetzbare Ergebnisse liefern.

Hybride Verfahren: Neben den statistischen und nicht statistischen Verfahren gibt es den Ansatz, diese beiden Verfahren zu kombinieren. Insbesondere werden Kombinationen von statistischen Modellen mit Detektorinformationen sowie ÖPNV-Funkbarken diskutiert. Auch hier ist der Aufwand, der mit der flächendeckenden Akquisition dieser Informationen verbunden ist, nicht minder groß. Hinsichtlich der Detektordaten gilt eben erwähntes, ÖPNV-Funkdaten dagegen sind unverschlüsselt und könnten abgehört werden. Die Problematik hierbei ist jedoch, dass im betrachteten Gebiet Empfänger installiert und vernetzt werden müssen.

3.3 Anforderungen an eine Prognose

Schätzungen zukünftiger Signalzustände (Schaltzeitprognosen) sollten nicht nur möglichst exakt sein, sie sollten auch eine Interpretation darüber zulassen, wie sehr der Prognose vertraut werden kann. Ein gängiges Mittel hierzu ist die Berechnung einer Auftretenswahrscheinlichkeit des vorhergesagten Ereignisses. Man spricht hier auch vom Grad des Dafürhaltens (bzw. Grad der Gewissheit oder Grad der Überzeugtheit). Jede der geplanten Kundenfunktionen benötigt einen solchen Grad des Dafürhaltens einer Schätzung zukünftiger Schaltzeiten. Ist z.B. bekannt, dass die Wahrscheinlichkeit eines Wechsels von Grün auf Rot bei Erreichen der entsprechenden Signalgruppe bei 100% liegt, so könnte eine „Prepare-to-Stop“-Warnung ausgegeben werden. Liegt diese bei z.B. nur 80%, so wäre eine „Prepare-to-Stop“-Warnung in jedem 5. Fall inkorrekt und könnte hier zu einem Fehlverhalten des Fahrers führen. Dieses Beispiel macht klar, dass Ampelassistentenfunktionen zwingend einen Grad des Dafürhaltens verwendeter Schaltzeitprognosen bedürfen. Dabei können die Anforderungen an diese variieren. Für eine schaltzeitoptimierte Start-Stop-Automatik etwa könnte schon ein Wert von 80% ausreichend sein, während dies für die „Prepare-to-Stop“-Warnung unwahrscheinlich scheint.

Wahrscheinlichkeitskurve: Um einen Grad des Dafürhaltens verwendeter Schaltzeitprognosen zu definieren, wird für Schaltzeitprognosen der Begriff der „Wahrscheinlichkeitskurve“ eingeführt. Diese repräsentiert einen sekunden-diskreten Zeilenvektor und gibt für jeden zeitdiskreten Wert die Wahrscheinlichkeit für einen prognostizierten Signalzustand an. Dabei wird unterschieden




Abbildung 3.1: Typischer Verlauf einer Wahrscheinlichkeitskurve (Freigabe- oder Grünwahrscheinlichkeit).

zwischen der Grünwahrscheinlichkeit

$$P(\text{grün}) = \hat{g} = (\hat{g}_1, \dots, \hat{g}_n) \quad (3.1)$$

und der Rotwahrscheinlichkeit

$$P(\text{rot}) = 1 - P(\text{grün}) = \hat{r} = (\hat{r}_1, \dots, \hat{r}_n). \quad (3.2)$$

Dabei gilt: $P(\text{grün}), P(\text{rot}) \in [0, 1]$. n stellt die Länge des Zeilenvektors dar und repräsentiert den zeitlichen Horizont in die Zukunft in Sekunden (Gültigkeitsbereich). Ein typischer Verlauf einer solchen Wahrscheinlichkeitskurve ist in Abbildung 3.1 dargestellt.

Qualitätsmetrik: Die in Abbildung 3.1 dargestellten Wahrscheinlichkeitswerte geben a priori einen Grad des Dafürhaltens an, also vor Bekanntwerden der tatsächlichen Schaltzeiten. Ob diese korrekt im mathematischen Sinne waren, d.h. ob der Anteil der als richtig rot und richtig grün klassifizierten Zeitbereiche möglichst hoch war, wird anhand der Korrektklassifikationsrate (KKR) (auch Treffergenauigkeit oder Vertrauenswahrscheinlichkeit, englisch: accuracy genannt) gemessen. Sie gibt den Anteil der korrekt klassifizierten Objekte an und ist definiert wie folgt:

$$KKR = \frac{\text{richtig klassifiziert}}{\text{durchgeführte Tests}} = \frac{r_g + r_r}{r_g + f_g + r_r + f_r}, \quad (3.3)$$

wobei r_g und r_r die richtig grün und richtig rot klassifizierten Signalzustände angeben, f_g und f_r die falsch grün und falsch rot klassifizierten Signalzustände darstellen.

Jedoch erfolgt aus einer Wahrscheinlichkeitskurve noch keine Klassifikation.

Diese wird durch Verwendung einer Schwellwertfunktion erreicht:

$$\widehat{g}_i := \begin{cases} 1, & \text{wenn } \widehat{g}_i \geq th_u \\ 0, & \text{wenn } \widehat{g}_i \leq th_l \end{cases}, \quad (3.4)$$

wobei th_l einen unteren Schwellwert und th_u einen oberen Schwellwert darstellen. Eine Schaltzeitprognose g_i zu einem Zeitpunkt i ist dabei nur dann zulässig und geht in die Klassifizierung mit ein, wenn sie den Zustand 1 (grün) oder 0 (rot) hat. Die Menge von Schaltzeitschätzungen \widehat{S} lässt sich sodann definieren wie folgt:

$$\widehat{S} = \{\widehat{g}_i | (\widehat{g}_i = 1) \vee (\widehat{g}_i = 0)\} \quad (3.5)$$

Der Anteil an Signalzustandsschätzungen \widehat{S} an der Menge aller Signalzustände S ist definiert durch:

$$Ver = \frac{\widehat{S}}{S} \quad (3.6)$$

Dieser Wert wird nachfolgend als Verfügbarkeit Ver bezeichnet. Eine perfekte Prognose würde bei einer KKR von 1 und einer Verfügbarkeit von 1 vorliegen. In diesem Fall wären alle Signalzustände mit korrekten Prognosen belegt. In der Realität jedoch sind Prognosen nie perfekt. Diese zeichnen sich durch einen sich stetig ändernden Grad des Dafürhaltens aus. Ob dieser zum relevanten Zeitpunkt ausreichend ist, kann durch die Kundenfunktion anhand der Wahl eines passenden Schwellwertes th_l, th_u bestimmt werden. Ist eine hohe KKR die Anforderung der Kundenfunktion, so könnte diese auf Kosten der Verfügbarkeit weiter erhöht werden, indem nur solche Schätzungen ausgegeben werden, deren Grad des Dafürhaltens sehr hoch ist. In diesem Fall würden z.B. $th_l \leq 0,01$ und $th_u \geq 0,99$ gewählt. Lässt man umgekehrt mehr Aussagen zu (steigert man also die Verfügbarkeit), so sinkt deren KKR. Man kann hier von konkurrierenden Zielbeziehungen sprechen.

3.4 Bestehende Ansätze zur Schaltzeitprognose mit Schaltinformationen

Im Folgenden werden bestehende Ansätze zur Rekonstruktion und Prognose zukünftiger Signalzustände auf Basis verfügbarer Schaltzeitinformationen beschrieben. Je nach Land, Lichtsignalanlagen-Architektur und Stand der Technik können verfügbare Informationen und Latenzzeiten divergieren. Entsprechend unterscheiden sich auch die Ansätze. Zunächst werden Arbeiten anderer Autoren vorgestellt, anschließend erfolgt eine Zusammenfassung der dieser Arbeit vorangegangener Forschungsarbeit des Autors.

3.4.1 Ansätze aus verwandten Arbeiten

Koukoumidis et al. stellen ein auf Mobilgeräte gestütztes Verfahren zur Prognose von festzeitgesteuerten Lichtsignalanlagen im US-amerikanischen Raum vor, das auch für verkehrsabhängige Lichtsignalanlagen angewendet werden kann [62]. Hierbei sollen mit einem an der Windschutzscheibe befestigten Smartphone Videobilder verarbeitet und so die derzeitigen Phasen von Lichtsignalanlagen an Kreuzungen bestimmt und an einen Server geschickt werden, um sie für andere Anwender des Systems nutzbar zu machen. Mithilfe dieses Ansatzes ist es laut Koukoumidis et al. möglich, festzeitgesteuerte Lichtsignalanlagen mit einer durchschnittlichen Abweichung von 0,66 Sekunden vorherzusagen. Überdies wird ein Verfahren zur Vorhersage von verkehrsabhängigen Lichtsignalanlagen vorgestellt und dieses anhand von singapurischer (Bugis) und US-amerikanischer Lichtsignalanlagen (Massachusetts Avenue) evaluiert. Hierzu sammeln sie vergangene Signalisierungsdaten und trainieren damit ein Support-Vector-Regressionsmodell. Koukoumidis et al. zufolge konnte so eine Vorhersage mit einer durchschnittlichen Abweichung von 2,45 Sekunden erreicht werden [62]. Anzumerken ist hierbei, dass nur zwei Straßenzüge betrachtet wurden und auch das verwendete Maß zur Bestimmung der durchschnittlichen Abweichung nicht näher beschrieben wurde.

Weisheit führt einen Prognoseansatz vor, der die Support Vector Machine (SVM) verwendet [63]. Dabei verwendet er Echtzeitdetektorinformationen der an den Lichtsignalanlagen verbauten Induktionsschleifen als Eingangsgröße, die entsprechenden Schaltzeiten als Ausgangsgröße. Für den Prädiktionsprozess trainiert er die SVM mit einer definierten Trainingsmenge von vergangenen Schaltzeitinformationen (Signalzustände, Umlaufzeit und Detektor-Informationen) für zwei Kreuzungen in Düsseldorf. Im Vergleich zur bloßen Verwendung von Schaltzeitinformationen ist er so in der Lage, die Prognosequalität zu steigern. Obgleich er mit diesem Ansatz sehr vielversprechende Ergebnisse erzielt, wurde dieser Ansatz nicht in einem größeren Testfeld evaluiert. Ferner ist dieser Ansatz auch auf eine niedrige Datenlatenz (weniger als drei Zyklen) angewiesen und benötigt Detektor-Informationen, die nicht immer zur Verfügung stehen.

Im Rahmen eines Big-Data-Projektes der BMW Group wurden 2013 Schaltzeitinformationen sechs ausgewählter Kreuzungen an das Unternehmen Pivotal (früher Greenplum) zu deren Analyse sowie zur Konzeption von Vorhersagemodellen übergeben. So sollten zusätzliche Ideen bzw. Konzepte zur Herangehensweise an die Analyse von Big Data durch ein „Big Data Analytics“-Unternehmen erhalten werden. Mithilfe gängiger Data-Mining-Verfahren zur Extraktion von Informationen konnte von Pivotal festgestellt werden, dass die Umlaufzeiten von Lichtsignalanlagen stets ähnliche Längen zu haben scheinen. Auch wurde entdeckt, dass bestimmte Umlaufzeiten besonders häufig auftreten. Geschuldet ist dies im deutschen Raum nach RiLSA definierten festen Umlaufzeiten und Programmwechseln (vgl. Abschnitt 2.3.3.3). Zu dieser Erkenntnis gelangten die Data-Scientists von Pivotal jedoch nicht, da sie auf die

Betrachtung von Zusatzinformationen über den Aufbau von Lichtsignalanlagen in Deutschland (etwa RiLSA [25]) verzichteten. Dies führte zu der Fehlinterpretation, dass bei deutschen Lichtsignalanlagen die Umlaufzeiten je nach Verkehrslage verlängert oder verkürzt werden, wie es bei anderen Verfahren (z.B. SCATS/SCOOTs, Abschnitt 2.3.3) der Fall sein kann. Davon ausgehend wurde durch Pivotal das ARIMA-Forecasting-Modell zur Vorhersage von zukünftigen Umläufen vorgeschlagen [64]. Dabei ist jedoch nicht die Vorhersage von Umläufen (diese sind bekannt), sondern von Umschaltzeitpunkten das Ziel.

Ein weiterer, jedoch proprietärer Ansatz wurde durch das Unternehmen GEVAS Software entwickelt. Im Rahmen des Förderprojektes UR:BAN (vgl. Abschnitt 2.2.2) entwickelten die Fachkräfte Konzepte zum Aufbau von Teilkomponenten städtischer und kommunaler Verkehrssysteme, um einen Austausch und Interaktionen mit externen Partnern zu ermöglichen. Ziel ist die Ausgestaltung und anschließende Nutzung der Systeme zur Prognose zukünftiger Schaltzeiten. Im Rahmen dieser Arbeit wurde durch GEVAS Software ein Prognoseverfahren auf Basis vergangener Schaltzeiten entwickelt und der Stadt Düsseldorf für einen befristeten Zeitraum bereitgestellt. Da es sich bei dem Verfahren um einen nicht veröffentlichten Ansatz handelt, wurde dieser durch den Abteilungsleiter für Verkehrsmanagement und Forschung von GEVAS Software, Dr. Peter Maier erläutert und freundlicherweise die Erlaubnis zur Beschreibung im Rahmen dieser Arbeit erteilt. Bei diesem Ansatz werden ebenfalls Wahrscheinlichkeitskurven (vgl. Abschnitt 3.3) für Schaltzeitprognosen erstellt. Hierzu werden direkt vorangegangene Schaltereignisse individueller Lichtsignalanlagen verwendet und Häufigkeiten von Grün- und Rotzeiten innerhalb eines Umlaufes bestimmt. Wie viele vergangene Schaltzeiten in die Berechnung einfließen, ermitteln sie anhand von Tagesupdates. Eine technische Detaillierung erfolgt an geeigneter Stelle im Abschnitt 3.6.1.2.

3.4.2 Beiträge aus Vorarbeiten: Kalman Filter Ansatz

In einer vorangegangenen Arbeit des Autors wurde ein erstes Modell zur Schätzung zukünftiger Schaltzeiten mithilfe des Kalman Filter (KF) vorgestellt [65]. Dieses Modell wurde auf Basis von vergangenen Schaltzeiten von sechs Münchener Lichtsignalanlagen entwickelt. Die Ergebnisse wurden im Rahmen dieser Arbeit erweitert und in [106] veröffentlicht.

Für die Entwicklung des Algorithmus standen vergangene Schaltzeitdaten für sechs Münchener Lichtsignalanlagen zur Verfügung. Zugleich wurde eine Schnittstelle zum Kreisverwaltungsreferat (KVR) München etabliert, die zur Übermittlung der jeweils aktuellsten Schaltzeiten dieser Lichtsignalanlagen diente. Die Latenzzeit betrug zwischen 3 und 45 Minuten. Ziel war es, auf Basis der vorangegangenen Schaltzeiten eine Prognose zukünftiger Schaltzeiten zu generieren. Dabei musste ein Verfahren gefunden werden, welches in der Lage ist, Latenzzeiten bei der Datenübertragung, Verarbeitung und dem Prognoseprozess überbrücken zu können.

Mit dem entwickelten Verfahren konnten für die sechs verfügbaren Lichtsignalanlagen bei einer Latenzzeit von 3 Minuten Prognosen mit einer KKR von 0,95 und einer Verfügbarkeit von 0,56 erreicht werden. Mit einer geringeren Anforderung an die KKR von 0,9 konnte die Verfügbarkeit auf 0,82 gesteigert werden. Ferner ist es mit dem vorgestellten Ansatz möglich, Prognosen einfach zu parallelisieren. So könnten zukünftige Schaltzeiten einer jeden individuellen Lichtsignalanlage in einem selbständigen Prozess prognostiziert werden.

Im Rahmen der weiterführenden Forschungsarbeiten für diese Arbeit wurde vom KVR München Schaltzeitinformationen für eine größere Menge von Lichtsignalanlagen (ca. 700-800) zur Verfügung gestellt. Bei der Performanceanalyse des Kalman Filter Ansatzes stellte sich, auch bei massiver Parallelisierung der Verarbeitungsschritte heraus, dass eine Schaltzeitprognose nicht in einem zufriedenstellenden Zeitrahmen erstellt werden kann. Obwohl Kalman Filter Verfahren in der Literatur als sehr performant eingestuft werden, kostete insbesondere der Invertier-Prozess des Terms $(HP_{k|k-1}H^T + R)$, für die Menge von knapp 800 Lichtsignalanlagen zu viel Rechenzeit. Obgleich mit dem konzipierten System eine deutliche Qualitätssteigerung der Prognosen nachgewiesen werden konnte, skaliert es nicht. Eine Alternativlösung muss gefunden werden.

3.5 Rückkopplungssystem zur Schaltzeitprognose

Ziel ist es, ein Verfahren zu finden, das eine dem Kalman Filter möglichst vergleichbare Qualität liefert und sich gleichzeitig durch eine deutlich geringere Rechenzeit auszeichnet. Ferner soll sichergestellt sein, dass auch beim zu entwickelnden Verfahren eine horizontale Skalierung weiterhin gegeben ist. Es soll möglich sein, weitere urbane Ballungsräume lediglich durch Hinzunahme zusätzlicher Knoten mit Prognosen zu versorgen. Nachfolgend wird ein Rückkopplungssystem [103, 104, 105] vorgestellt, das diesen Anforderungen genügt.

3.5.1 Datengrundlage für die Schaltzeitprognose

Zur Entwicklung eines skalierbaren Prognosesystems wurden durch das KVR München mittels einer ISDN-Schnittstelle zyklisch Schaltzeiten zur Verfügung gestellt. Dabei wurde seitens KVR eine Taktfrequenz von 2 Minuten gewählt, was gleichzeitig die derzeit höchste technisch realisierbare Aktualisierungsrate seitens KVR München darstellt. Die Latenzzeit dieser Daten konnte im Rahmen einer Servererneuerung auf 2-5 Minuten reduziert werden. Gesendet wurden drei unterschiedliche Informationen, die im Vorfeld ausgehandelt wurden:

- **Signalprogrammauflösungen:** Um Prognosen tätigen zu können, muss zunächst bekannt sein, ob aktuelle Programme auch prognostizierbare sind. Verkehrsabhängige Lichtsignalanlagen müssen jederzeit in

der Lage sein, bei Störungen in Festzeit-Ersatzprogramme wechseln zu können. Daher muss die Information vorliegen, ob die betrachtete Lichtsignalanlage derzeit tatsächlich in einem VA-Programm läuft. Die Auflösung von Programmnummer zu Programmtyp erfolgt mithilfe der Programmbezeichnungen. Der Inhalt einer solchen Datei wird exemplarisch dargestellt:

```
LZANR ; PRG_NR ; PRG_TYP
4 ; 1 ; VA
4 ; 4 ; VA
4 ; 11 ; FZ
4 ; 21 ; ST
4 ; 22 ; HS
```

Hierbei bezeichnet LZANR („Lichtzeichenanlage“) die ID der Lichtsignalanlage, PRG_NR die Programmnummer und PRG_TYP den Programmtyp.

- **Programmwechsellinformationen:** Verkehrsabhängige Lichtsignalanlagen sind üblicherweise auf zwei Stufen adaptiv: auf der Makroebene in Form von Programmen, die oftmals zeitpunktabhängig wechseln, sowie auf Mikroebene durch Verlängerung oder Verkürzung von Rot- und Grünzeiten. Die Liste aktueller Schaltzeiten gibt Aufschluss über die Verkehrsflussanpassung auf Makroebene. Der Inhalt sieht wie folgt aus:

```
LZA_ID ; SP_NR ; UMLAUF ; BT-FUNKTION ; OFFSET ; MODUS ; PRIO ; ZEIT
556 ; 4 ; 90 ; 31 ; 45 ; 254 ; 10 ; 27.11.2014 00:37:28
1004 ; 0 ; 0 ; 10 ; 0 ; 255 ; 10 ; 27.11.2014 00:37:28
```

Hierbei bezeichnet LZA_ID (Lichtzeichenanlage_ID) die ID der Lichtsignalanlage (entspricht LZANR; redundante Bezeichner), SP_NR die Programmnummer (entspricht PRG_NR, redundante Bezeichner). UMLAUF stellt die Umlaufzeit, BT-FUNKTION die Betriebsfunktion, OFFSET den Offset zum Umlauf in Hauptverkehrsrichtung dar. Der Modus bezeichnet den Modus der Lichtsignalanlage, PRIO die Priorität, ZEIT die Zeit. Es sei bemerkt, dass für die Prognose BT-FUNKTION, OFFSET, MODUS, PRIO nicht benötigt werden.

- **Schaltzeitinformationen:** Alle zwei Minuten werden Schaltzeiten aller verfügbaren Lichtsignalanlagen der vergangenen zwei Minuten (zuzüglich Latenzzeit) übertragen. Der Inhalt einer solchen Datei wird exemplarisch dargestellt:

```
SCHALTID ; JAHRTAG ; SEKUNDE ; LSANR ; SGNR ; ZUSTAND ; PROG NR ;
WELLECALC
279088637 ; 2014331 ; 131 ; 262 ; 1 ; 0 ; 1 ; 11
279088638 ; 2014331 ; 186 ; 262 ; 1 ; 1 ; 1 ; 66
279088639 ; 2014331 ; 145 ; 262 ; 2 ; 1 ; 1 ; 25
279088640 ; 2014331 ; 165 ; 262 ; 2 ; 0 ; 1 ; 45
```

Wobei SCHALTID die ID des Schaltereignisses darstellt, JAHRTAG den Tag im Jahr repräsentiert (2014331 entspricht dem 331. Tag im Jahr 2014) und SEKUNDE die Sekunde am derzeitigen Tag seit Null Uhr darstellt, in der ein Schaltevent auftrat. Die Bezeichnung LSANR stellt die vom Schaltevent betroffene Lichtsignalanlage dar, SGNR die vom Schaltevent betroffene Signalgruppe der Lichtsignalanlage und ZUSTAND den eingetretenen Zustand (1=Grün, 0=Rot). PROG NR bezeichnet die Programmnummer (entspricht PRG_NR, redundante Bezeichner), WEL-LECALC stellt eine Zusatzinformation für die Koordinierung in einer Welle dar und ist für die Prognose nicht relevant.


Insgesamt müssen ca. 40.000 Datensätze pro Aktualisierung verarbeitet und daraus Schaltzeitprognosen generiert werden.

3.5.2 Funktionsbeschreibung des Rückkopplungssystems

Verkehrsabhängige Lichtsignalanlagen haben sehr charakteristische Muster, Grün- und Rotphasen entsprechend der derzeitigen Verkehrssituation anzupassen. Vereinfacht verlängern verkehrsabhängige Steuerungsverfahren eine Grünphase, wenn durch den zugehörigen Detektor eine große Menge von Überquerungen gemessen wird. Der Verkehr wiederum hat ebenfalls sehr charakteristische Muster - abhängig von Zeit, Position und Tag. In den Morgenstunden fahren viele Fahrzeuge in die urbanen Zentren und abends zurück, aber auch im Tagesverlauf können Spitzen existieren. Diese Muster unterscheiden sich für jede Lichtsignalanlage und hängen von der jeweiligen Position, Zeit und Tag ab. Sie müssen implizit durch das Prognoseverfahren erfasst werden können.

In Abbildung 3.2a sind Signalzustände einer zufälligen Lichtsignalanlage abgebildet. Die grauen Bereiche repräsentieren Grünsignale, die weißen repräsentieren Rotsignale. Die Signalzustände sind entsprechend ihrer Umlaufzeit T (hier 90) dargestellt. Wie man an den beiden Linien des gleitenden Mittelwertes beobachten kann, variiert die umlaufzeitrelative Zeit der Signalwechsel im Tagesverlauf. In den Morgen- und Abendstunden finden Signalwechsel vermehrt früher statt als zur Mittags- und Nachmittagszeit. Obgleich diese Verhaltensweisen je nach Lichtsignalanlage, Zeit und Tag variieren können, sind Muster jedoch stets erkennbar.

Nachfolgend wird die relative Grünhäufigkeit zu jedem Zeitpunkt der Umlaufzeit errechnet: Die illustrierten vergangenen Signalzustände können als Matrix $B = (b_{ij})_{i=1,\dots,m;j=1,\dots,n} \in \mathbb{B}^{m \times n}$ von binären sekundenweise getakteten Signalzuständen dargestellt werden, wobei 0 rot und 1 grün repräsentieren. Dabei entspricht die Dimension m der Umlaufzeit T , die Dimension n der Anzahl der in die Berechnung der Häufigkeit einbezogenen Umläufe ϑ . In Abbildung 3.2a würde dies der Anzahl von Umläufen zwischen 6:00 Uhr und 21:00 Uhr entsprechen. Ausgehend von dieser Matrix werden für die Abbildungen 3.2b und 3.2c die beiden Submatrizen B_{IJ_1} und B_{IJ_2} mit unterschiedlichem ϑ gebildet. Ferner wurde für diese Abbildung die relative Grünhäufigkeit zu jedem



(a) Signalzustände relativ zur Umlaufzeit.




 (b) Relative Häufigkeiten für ein großes ϑ .

 (c) Relative Häufigkeiten für ein kleines ϑ .

Abbildung 3.2: Signalzustände im Tagesverlauf (a) und relative Grünhäufigkeiten (b) und (c) für die hervorgehobenen Bereiche aus (a).

Zeitpunkt der Umlaufzeit errechnet. Diese ergibt sich wie folgt:

$$g = \frac{\sum_{j=1}^n b_{ij}}{\vartheta} \quad (3.7)$$

Dabei repräsentiert der Zeilenvektor g sekundenweise Grünhäufigkeiten. Ein intuitives und im Vergleich zum KF-Modell deutlich einfacheres Modell ist der Ansatz, die relativen Grünhäufigkeiten als Grünwahrscheinlichkeiten anzunehmen. Im Gegensatz zum KF-Modell wird darauf verzichtet, auf Basis des Trends der vorgegangenen Zustände einen neuen Zustand zu schätzen. Stattdessen wird davon ausgegangen, dass der zukünftige Signalzustand den letzten Signalzuständen entspricht. Dies ist zulässig, da nach dem Gesetz der Großen Zahlen die relative Häufigkeit eines Ereignisses dessen Wahrscheinlichkeit approximiert. Umgekehrt kann man folgern, dass dieser Wahrscheinlichkeitswert bei immer kleiner werdendem ϑ mit einem immer größeren Unsicherheitsfaktor behaftet ist (man diesem also immer weniger trauen kann). Dies spiegelt sich in einer niedrigeren KKR wider. Auf der anderen Seite darf ϑ nicht beliebig groß gewählt werden, wie folgendes Beispiel klar macht: Wählt man bei Anwendung der Schwellwertfunktion 3.5.2.1 einen Schwellwert von $th_u = 0,95$ und $th_l = 0,05$, so wäre der Anteil Ver von Schaltzeitschätzungen \hat{S} für Abbildung

3.2b bei nur 32%, in Abbildung 3.2c jedoch bei 71%. Anhand dieses Beispiels wird deutlich, dass mit diesem einfachen Instrument die Verfügbarkeit deutlich gesteigert werden kann, jedoch auf Kosten der KKR.

3.5.2.1 Das Rückkopplungssystem

Im Folgenden wird ein Rückkopplungssystem (RS) (auch Feedback-System oder Regelsystem genannt) vorgestellt, welches die Aufgabe hat, laufend Prognosen zu erstellen und deren Qualität zu überwachen. Speziell soll gewährleistet sein, dass insbesondere die KKR auf dem von der Ampelassistentenfunktion geforderten Niveau bleibt; gleichzeitig sollen Prognosen eine möglichst hohe Verfügbarkeit Ver aufweisen. Es muss also ein optimales ϑ gefunden werden. Da dieser Wert je nach Lichtsignalanlage und Verkehrsaufkommen unterschiedlich sein kann, muss über eine Überwachungseinheit die Qualität der getätigten Prognose einer jeden Lichtsignalanlage anhand der tatsächlichen Schaltzeiten evaluiert werden. Sodann muss ϑ für jede neue Prognose und jede einzelne Lichtsignalanlage neu bestimmt werden. Im Folgenden werden die Komponenten und die Konzeption des RS beschrieben und die einzelnen Komponenten, sowie deren Parametrisierung dargestellt. Mit einer Aktualisierungsrate von etwa zwei Minuten werden die jeweils neuesten Schaltzeitinformationen vom KVR München an einen FTP-Server verschickt. Aufgrund Lichtsignalanlagen-spezifischer Eigenschaften und der Netzverzögerungen liegen die aktuellsten Schaltzeitdaten etwa drei bis fünf Minuten in der Vergangenheit. Ein selbst entwickeltes Skript dient zur Überwachung des FTP-Servers. Werden dort neue Schaltzeitinformationen abgelegt, werden diese an den eigenen Prognoseserver weitergeleitet, wodurch die Berechnung neuer Prognosen angestoßen wird. Der gesamte Prozess der Prognosegenerierung und -überwachung ist in Abbildung 3.3 dargestellt.

Erstellung von Schaltzeitschätzungen \hat{S} : Neueste Schaltzeitinformationen werden zum Prognosemodul (I) weitergeleitet, welches neue Grünwahrscheinlichkeitskurven für jeden Fahrverkehr einer jeden Lichtsignalanlage berechnet und die Schwellwertfunktion anwendet. Insgesamt werden durch das KVR Schaltzeitinformationen für ca. 800 Lichtsignalanlagen versendet. Da Prognosen für jede Signalgruppe einer Lichtsignalanlage zu berechnen sind, werden ca. 6.000 Schaltzeitschätzungen erstellt. Diese werden in eine Datenbank (II) abgelegt. Prognosen haben einen Gültigkeitszeitraum von $(t, t + a)$, wobei t der aktuelle Zeitpunkt ist und a dem Aktualisierungsintervall der neuesten Schaltzeiten entspricht. Zur Erstellung der Prognose wird in der Regelstrecke (IV) der Parameter ϑ für die jeweilige Lichtsignalanlage nachgesehen.

Qualitätsüberwachung: Nach der Erstellung der Prognosen wird die KKR einer jeden Lichtsignalanlage der zuvor erstellten Schaltzeitschätzung \hat{S} (Zeitraum $(t - (2d + a), t - (d + a))$) berechnet, wobei d die Latenzzeit darstellt. Dies erfolgt durch Abgleich mit den entsprechenden Schaltzeiten. Die Ergebnisse werden an den Regler rückgeführt und die Abweichungen des Ist- vom

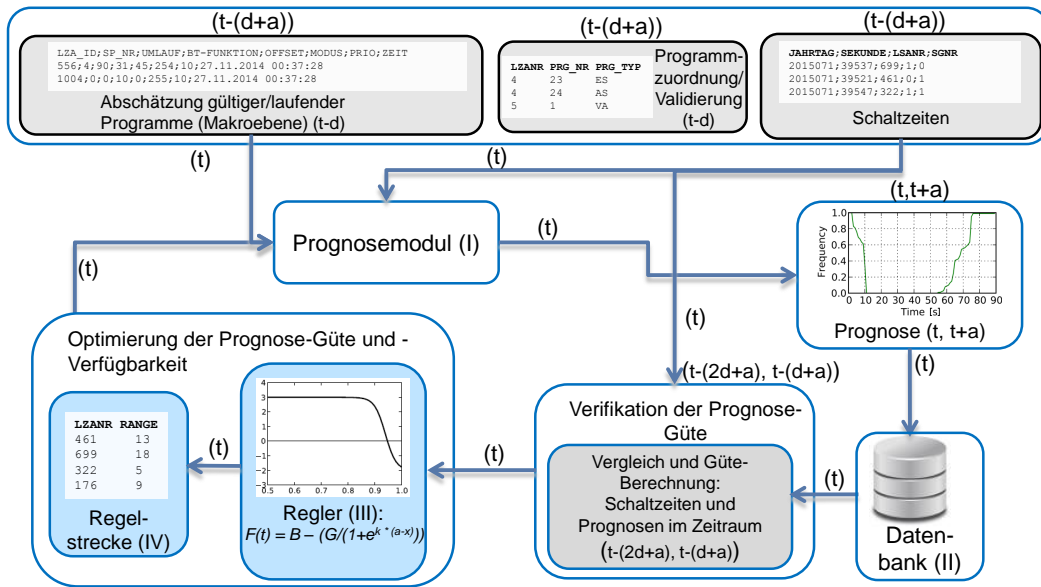


Abbildung 3.3: Rückkopplungssystem mit zyklischer Überwachung der generierten Prognosen. Mit jeder Übermittlung der neuesten Schaltzeiten wird die Generierung neuer Prognosen getriggert. Erreichen die Prognosen nicht den erforderlichen Qualitätsstandard, wird eine Nachjustierung der Prognoseparameter vorgenommen.

Sollwert bestimmt. Der Sollwert stellt dabei eine Mindestanforderung an die KKR dar, die aus der individuellen Kundenfunktion abgeleitet wird. Üblicherweise liegen diese im Bereich zwischen 90% und 95% (vgl. Abschnitt 3.3).

Anpassung der Regelstrecke: Die Parameteranpassung der durch den Regler (III) zur Erreichung eines vorgegebenen Sollwertes an der KKR ist der zentrale Bestandteil des RS. Einerseits sollte ein potentiell verfehler Sollwert im nächsten Schritt erfüllt sein. Andererseits sollte die KKR bei über-erfüllten Sollwerten reduziert werden, um die Verfügbarkeit von Prognosen zu steigern. Dabei sollte vermieden werden, dass eine Überanpassung zu einer nicht Erreichung des Sollwertes im nächsten Schritt führt. Die Reaktion sollte also adäquat zur Größe des Fehlers, d.h. der Abweichung vom Sollwert ausfallen. Dies kann mithilfe der S-Kurvenfunktion erreicht werden.

3.5.2.2 S-Kurvenfunktion

Die S-Kurvenfunktion ist definiert wie folgt:

$$f(t) = B - \frac{G}{1 + e^{k \cdot (a-x)}} \quad (3.8)$$

Dabei stellt G eine obere Schranke der Erhöhung von ϑ für den nächsten Schritt dar, B verschiebt die Kurve auf der y -Achse, k gibt die Steilheit im Wendepunkt an. Der Parameter a ist die Position des Wendepunkts und x repräsentiert die gemessene KKR (Eingabewert). Die Anpassung der Regelstrecke mithilfe der S-Kurvenfunktion bietet einen einzigartigen Vorteil: Der Umfang der Anpassung ist adäquat zur Abweichung vom Sollwert. Eine Verfehlung des Sollwertes etwa im zweistelligen Bereich führt zu einer größeren Anpassung als eine Verfehlung von wenigen Prozentpunkten.

Die Kalibrierung der s-Kurvenfunktion muss empirisch erfolgen. So beeinflusst die Wahl der Parameter (speziell obere Schranke, Wendepunkt, Steilheit) die KKR und die Verfügbarkeit unterschiedlich. Im Rahmen der vorliegenden Arbeit wurden unterschiedliche Parametersätze zur Erreichung einer KKR im Bereich zwischen 90% und 95% untersucht und die Werte $G = 20, a = 0,93, k = 30$ ermittelt.

3.6 Vergleichende Bewertung des Rückkopplungssystems

Drei alternative Verfahren müssen dem vorgestellten Rückkopplungssystem zur Schaltzeitschätzung hinsichtlich ihrer KKR, Prognoseverfügbarkeit, Rechenzeit und Anzahl durchschnittlich prognostizierter Lichtsignalanlagen gegenübergestellt werden. Einerseits ist hier das vom Autor in einer Vorarbeit entwickelte KF-Modell 3.4.2 anzuführen. Ein weiterer Ansatz wurde durch das Unternehmen GEVAS Software für Verkehrstechnik und Verkehrsmanagement vorgestellt. Ein dritter Ansatz ist ein Referenzverfahren mit fixen Umlaufzeitgrößen, welches als Benchmarksystem anzusehen ist. Um eine Vergleichbarkeit zu erreichen, müssen alle Verfahren implementiert und evaluiert werden. Dies wurde für für das Testfeld München vorgenommen.

3.6.1 Gegenübergestellte Prognoseverfahren im Überblick

Es erfolgt eine technische Beschreibung der Alternativverfahren. Die Eingangsgröße aller Verfahren stellen die vom KVR München gesendeten Schaltzeitinformationen dar.

3.6.1.1 Kalman Filter Ansatz

Analog zum RS wird für eingehende Schaltzeiten eine Grünwahrscheinlichkeit nach Formel 3.7 errechnet. Im Prädiktions-Modul wird sodann ein Schätzung des Systemzustands

$$\tilde{x}_{k|k-1} = A\tilde{x}_{k-1|k-1}$$

durchgeführt. A repräsentiert die Systemmatrix. Die Veränderung der Verkehrssituation wird als linear betrachtet und durch die Funktion

$$d_{j,k} = g_{j,\vartheta_k} - g_{j,\vartheta_{k-1}}$$

beschrieben. Dabei beschreibt $d_{j,k}$ das Delta zwischen den Grünwahrscheinlichkeiten in den Zuständen k und $k - 1$. Der Systemzustand \tilde{x}_k ist beschrieben durch:

$$(g_1, \dots, g_n, d_1, \dots, d_n)_k^T \in R^{2n}.$$

Die Systemmatrix A hat folgende Gestalt:

$$\begin{pmatrix} g_1 \\ g_2 \\ \dots \\ g_n \\ d_1 \\ d_2 \\ \dots \\ d_n \end{pmatrix}_k = \begin{pmatrix} 1 & 0 & \dots & 0 & 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 & 0 & 1 & \dots & 0 \\ 0 & 0 & \dots & 0 & 0 & 0 & \dots & 0 \\ \cdot & & & & & & & \cdot \\ \cdot & & & & & & & \cdot \\ \cdot & & & & & & & \cdot \\ 0 & 0 & \dots & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 1 & 0 & 0 & \dots & 1 \end{pmatrix} \cdot \begin{pmatrix} p_1 \\ p_2 \\ \dots \\ p_n \\ d_1 \\ d_2 \\ \dots \\ d_n \end{pmatrix}_{k-1}.$$

Im Korrektur-Modul wird der Kalman-Gain berechnet:

$$K_k = P_{k|k-1} H^T (H P_{k|k-1} H^T + R)^{-1}.$$

Die Varianz des Messfehlers R wird bestimmt durch die Varianzen der individuellen Grünwahrscheinlichkeiten g_1, \dots, g_n . Für die Prädiktion werden wieder die Standard-KF-Prozesse verwendet:

$$\tilde{x}_{k|k} = \tilde{x}_{k|k-1} + K_k(z_k - H\tilde{x}_{k|k-1})$$

und

$$P_{k|k} = (I - K_k H) P_{k|k-1}$$

sowie

$$P_{k|k-1} = A P_{k-1|k-1} A^T + Q.$$

Q wird dabei analog zu R berechnet. Für eine detailliertere Beschreibung sei auf [106] verwiesen.

3.6.1.2 Statische Aktualisierung nach GEVAS Software

GEVAS Software entwickelte im Rahmen des Förderprojektes UR:BAN ein Prognoseverfahren, das sogenannte „Tagesaktualisierungen“ durchführt. Es wurde durch das Unternehmen bisher nur für das Testfeld Düsseldorf umgesetzt, weswegen eine eigene Implementierung für das Testfeld München vonnöten ist. In diesem Ansatz werden am Ende des Tages optimale Werte für den Parameter ϑ zu unterschiedlichen Zeiten des Tages bestimmt. Die Idee hierbei ist, dass der Verkehr an den jeweiligen Wochentagen beliebiger Wochen äh-

lich ausfällt. Es wird also in einer Tabelle, für jeden Wochentag und diskreten Zeitraum des Tages, der jeweilige Wert von ϑ abgelegt, der am entsprechenden Tag der Folgeweche abgefragt werden kann. Für die vorliegende Arbeit wurde ein Intervall von 15 Minuten für jedes ϑ gewählt. Die Berechnung einer Grünwahrscheinlichkeit erfolgt bei GEVAS Software, analog zum eigenen Ansatz, mithilfe der Formel 3.7.

3.6.1.3 Fixe Umlaufzeitgröße

Ein Referenzverfahren, das als Benchmark dient, stellt die Wahl einer fixen Umlaufzeitgröße zur Berechnung der Grünwahrscheinlichkeit dar, also die Wahl eines fixen ϑ . In der Implementierung wurde für ϑ ein Wert von 30 Umläufen verwendet.

3.6.2 Ergebnisse der vergleichenden Bewertung

Die vorgestellten Prognoseverfahren werden hinsichtlich KKR, Verfügbarkeit, Laufzeit und prognostizierten Lichtsignalanlagen bewertet. Dazu wurde ein Prognoseframework in der Programmiersprache Python [66] entwickelt. Um eine Vergleichbarkeit zwischen den Verfahren hinsichtlich der Rechenzeit zu gewährleisten, wurden dabei lediglich die Prognosemodule je nach Verfahren modifiziert. Der Zielwert für die KKR war hierbei 0,9 - 0,95. Für die Parameter th_u und th_l wurden entsprechend die Werte 0,93 und 0,07 gewählt. Die Ergebnisse sind in Tabelle 3.1 dargestellt.

Alle Verfahren weisen eine vergleichbare KKR von 0,914 - 0,919 auf. Die Verfügbarkeit von Prognosen dagegen variiert teilweise stark. Während sie beim Rückkopplungssystem und beim Kalman Filter ähnliche Werte im Bereich um 0,60 aufweist, so liegt sie bei der fixen Umlaufzeitgröße lediglich bei knapp 0,50. Die Verfügbarkeit statischer Tagesaktualisierungen beläuft sich auf 0,542. Zurückzuführen ist der deutliche Unterschied auf zweierlei Aspekte. Zum einen können das Rückkopplungssystem und der Kalman Filter direkt auf mikroskopische Verkehrsveränderung reagieren. Weiterhin sind sie in der Lage, Signalprogrammanpassungen zu erkennen und entsprechend zu reagieren. Beobachtbar ist dies anhand der Anzahl prognostizierbarer Ampeln in Abbildung 3.4. Beim Rückkopplungssystem und dem Kalman Filter sind deutliche Einschnitte um 9:00 Uhr und um 13:00 Uhr zu beobachten. Zu diesen Zeitpunkten wies ein großer Teil der Lichtsignalanlagen Signalprogrammanpassungen auf. Bei beiden Verfahren führt dies zu einem kurzfristigen Aussetzen der Prognose, da die erforderliche KKR kurzfristig nicht mehr erreicht werden kann. Erst bei Verfügbarkeit neuer Schaltzeitinformationen im aktuellen Signalprogramm werden wieder Prognosen generiert. Auch die statische Tagesaktualisierung ist in der Lage, Signalprogrammanpassungen zu berücksichtigen, da diese meist zeitplanabhängig und im Fall von München meist zu denselben Zeiten erfolgen.

| | Rückkopplungssystem | Kalman Filter | Fixe Umlaufzeitgröße | Tagesaktualisierungen |
|---|---|---|--|--|
| Beschreibung | Rückkopplungssystem mit s-Kurven-Funktion als Regler. | Schätzung der nächsten Grünverteilung auf Basis der vorangegangenen | Standardmäßig fließen die letzten 30 Umläufe ein | Statische Berechnung der optimalen Größe einfließender Umlaufzeiten am Tagesende |
| KKR | 0.914 | 0.917 | 0.919 | 0.911 |
| Verfügbarkeit | 0.578 | 0.593 | 0.499 | 0.542 |
| Laufzeit* | 67s | 191s | 52s | 54s (+15 Minuten Aktualisierung am Tagesende) |
| Prognostizierte Lichtsignalanlagen | 531 | 531 | 498 | 479 |

Tabelle 3.1: Gegenüberstellung der Prognoseverfahren. Vergleich hinsichtlich KKR, Verfügbarkeit, Laufzeit und prognostizierten Ampeln.

*Referenzimplementierung in Python, Modifikationen entsprechend des jeweiligen Algorithmus.

Dennoch liegt die Verfügbarkeit von Prognosen mit einem durchschnittlichen Wert von 0,542 unter der des Rückkopplungssystems, sowie des Kalman Filters. Auch hinsichtlich der durchschnittlichen Anzahl von Prognosen erreicht die statische Tagesaktualisierung die beiden erst genannten Verfahren nicht. Das Verfahren mit fixer Umlaufzeitgröße wird von allen Verfahren hinsichtlich der Verfügbarkeit und Anzahl prognostizierter Lichtsignalanlagen übertroffen, aufgrund seiner Einfachheit weist es jedoch die kürzeste Laufzeit auf.

Tabelle 3.1 und Abbildung 3.4 geben Aufschluss über die mittlere Prognosequalität (KKR und Verfügbarkeit), sowie Anzahl der prognostizierten Lichtsignalanlagen im zeitlichen Verlauf. Hier zeigt sich, dass KF und RS die KKR konstanter auf dem geforderten Niveau halten können, während bei den beiden anderen Verfahren immer wieder kleinere Einbrüche (etwa zwischen 12:00 und 13:00 Uhr) beobachtbar sind. Auch liegt die Anzahl zu prognostizierender Lichtsignalanlagen unter der des KF und RS.

Zur Betrachtung der Streuung der Prognosequalität nach Lichtsignalanlage sind in Abbildung 3.5 die KKR und die Verfügbarkeit anhand eines Streudiagramms angetragen. Dabei wurde für jede Lichtsignalanlage im Testfeld München die mittlere KKR und Verfügbarkeit der generierten Prognose berechnet. Die Position des Punktes kodiert die KKR/Verfügbarkeit-Kombination der prognostizierten Lichtsignalanlage. Im Vergleich der jeweiligen Abbildungen fällt auf, dass alle Verfahren geeignet sind, eine hohe KKR zu garantieren. In allen Fällen bildet sich eine Punktwolke im oberen Bereich des Diagrammes.

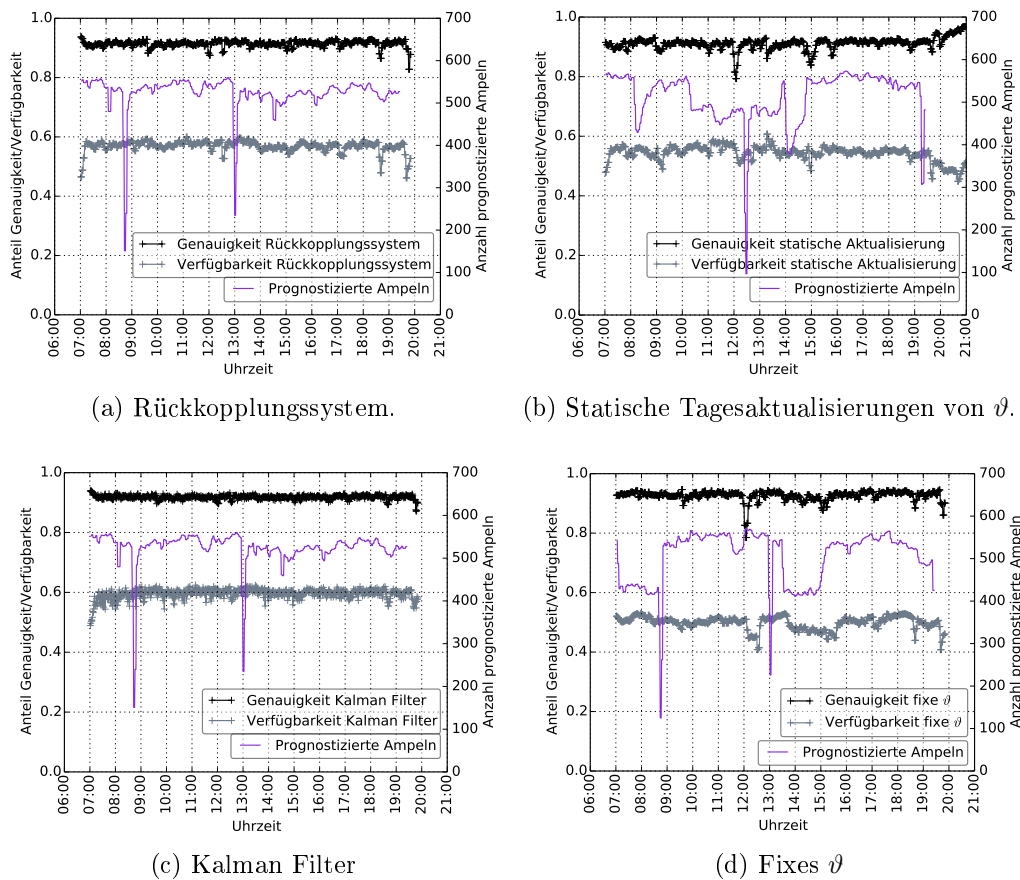


Abbildung 3.4: Gegenüberstellung der Prognoseverfahren hinsichtlich KKR, Verfügbarkeit und prognostizierten Lichtsignalanlagen im Tagesverlauf.

Gleichzeitig weisen alle Verfahren einen Zusammenhang zwischen KKR und Verfügbarkeit auf, was anhand der breiteren Streuung der KKR bei niedrigerer Verfügbarkeit deutlich wird. Umgekehrt weisen Prognosen mit hoher KKR meist auch eine hohe Verfügbarkeit auf. Speziell können das Rückkopplungssystem (Abbildung 3.5a) und der Kalman Filter (Abbildung 3.5b) die KKR vieler Lichtsignalanlagen steigern - im Vergleich zu den Abbildungen 3.5c und 3.5d wird dies anhand deutlich weniger Punkte im mittleren, rechten Bereich der Abbildungen sichtbar. Die KKR der betreffenden Lichtsignalanlage konnte so weit gesteigert werden, dass sich die KKR/Verfügbarkeit-Kombination in den linken oberen Bereich verschoben hat.

Abbildung 3.6 zeigt eine geographische Verortung der mit dem Rückkopplungssystem prognostizierbaren Lichtsignalanlagen in München. Dabei stellen blau gefärbte Kreise Lichtsignalanlagen, an denen Prognosen erlebbar sind, dar. Graue Kreise repräsentieren Anlagen, für die keine Prognosen mit ausreichender KKR generiert werden können, oder durch das KVR München keine Schaltzeitinformationen angeboten werden können. Die Verfügbarkeit der je-

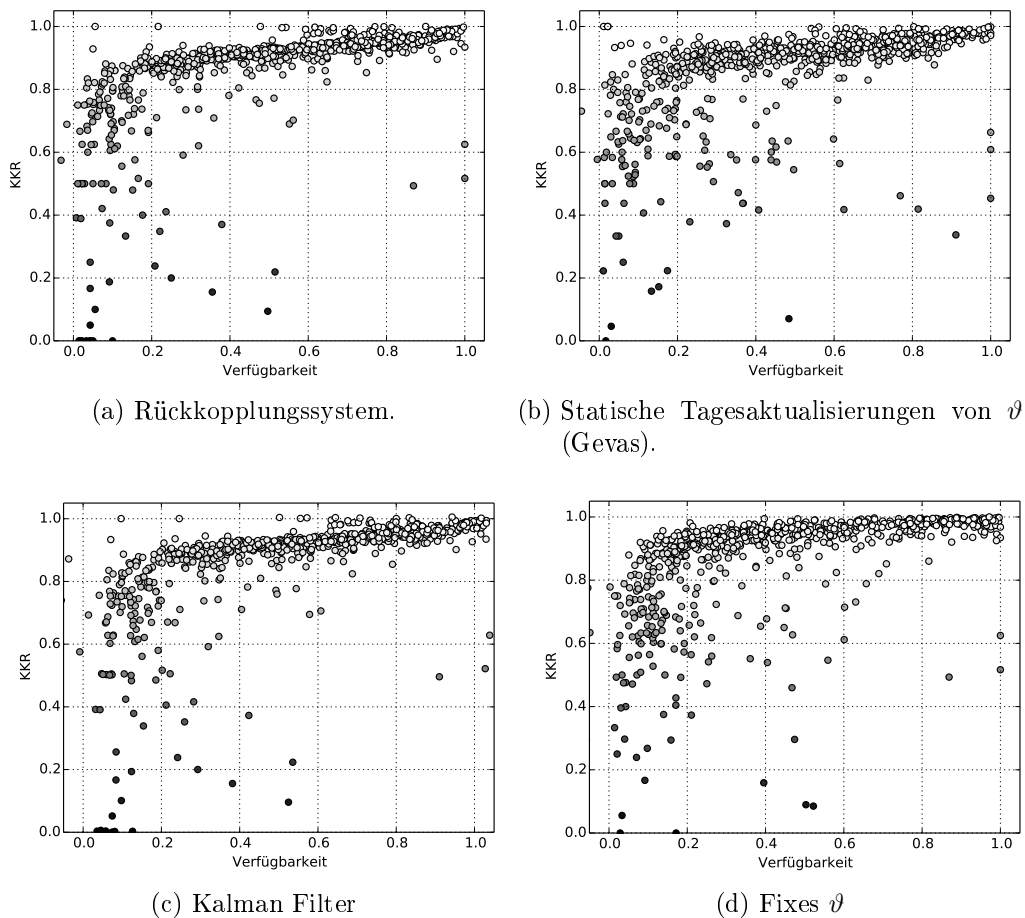


Abbildung 3.5: Gegenüberstellung der Prognoseverfahren hinsichtlich KKR und Verfügbarkeit anhand eines Streudiagrammes. Die Position des Punktes kodiert die KKR/Verfügbarkeit-Kombination der prognostizierten Lichtsignalanlage.

weiligen Prognose ist durch die Größe des jeweiligen (blauen) Kreises dargestellt. Anhand der Darstellung wird deutlich, dass speziell Hauptverkehrsadern besonders viele prognostizierbare Lichtsignalanlagen aufweisen. Dies ist konsistent mit der Annahme einer höheren Schaltzeitvolatilität an kleineren Straßen. Nicht selten verkehren hier nur wenige Fahrzeuge, die jedoch unmittelbar einen Signalwechsel veranlassen können (etwa bei bedarfsgesteuerten Anlagen). Lichtsignalanlagen an Hauptstraßen dagegen haben ein höheres Verkehrsaufkommen zu bewältigen, das sich durch weniger mikroskopische Veränderungen auszeichnet. Längerfristige Trends im Verkehrsaufkommen, die mit den vorgestellten Verfahren gut erfasst werden können (etwa Pendelverkehr), scheinen hier die Regel zu sein.

3.6.3 Folgerung

RS und KF weisen die beste Prognoseverfügbarkeit und höchste Anzahl zu prognostizierender Lichtsignalanlagen bei vergleichbarer KKR auf. Statische Tagesaktualisierungen und die Wahl fixer Umlaufzeiten können nicht an diese Ergebnisse heranreichen. Jedoch ist der KF aufgrund seiner hohen Laufzeit nicht für den Praxiseinsatz tauglich. Die Prognoseberechnung mit 191 Sekunden pro Schaltzeitaktualisierung liegt bereits über der Schaltzeitaktualisierungsrate des KVR von 120 Sekunden. Wie bereits angesprochen wurde, konnte die Invertierung des Terms $(HP_{k|k-1}H^T + R)$ als rechenintensivsten Teil ausgemacht werden.

Ausgehend von dieser Auswertung wurde eine Backend-Architektur für die Prognoseerstellung mithilfe des Rückkopplungssystems entworfen und in Zusammenarbeit mit der BMW Group für diese umgesetzt. Die Anforderung war, die Kundenfunktionen „Restrotanzeige“, „Prepare-to-Stop“ und „Grünband-Geschwindigkeitsempfehlung“ für eine Testflotte von bis zu 500 Fahrzeugen erlebbar zu machen. Dabei wurde die Frontend-Entwicklung (fahrzeugseitig) und Kommunikation mit dem Backend durch Mitarbeiter der BMW Group gesteuert. Ein HMI Vorschlag der Funktion „Restrotanzeige“ ist in Abbildung 3.7 dargestellt. Zu sehen ist hier eine prototypische Implementierung dieser Kundenfunktion in einem Versuchsträger der BMW Group. Der Signalgeber an der Kreuzung Ingolstädterstr./Frankfurter Ring zeigt den Signalzustand rot. Auf der Head-Unit wird eine Sekundenanzeige in Verbindung mit einer Statusleiste der verbleibenden Rotzeit (41 Sekunden) angezeigt. Diese Information wurde mittels Luftschnittstelle vom Prognose-Backend abgefragt. Die verbleibende Wartezeit wird bis zu einem Wert von fünf Sekunden herunter gezählt und verblasst ab diesem Wert langsam, damit der Fahrer vor dem unmittelbaren Grünbeginn seine Aufmerksamkeit wieder auf den Signalgeber richtet.

3.7 Zusammenfassung

In diesem Kapitel wurde ein skalierbares Verfahren zur Berechnung zukünftiger Schaltzeiten an verkehrsabhängigen Lichtsignalanlagen vorgestellt und für den Münchner Ballungsraum implementiert und getestet. Daten vergangener Schaltzeiten an signalisierten Knotenpunkten wurden dabei vom KVR München mit einer Latenzzeit von ca. zwei bis fünf Minuten zur Verfügung gestellt. In einer vergleichenden Analyse wurde der eigene Vorschlag des Prognosealgorithmus alternativen Ansätzen gegenübergestellt und anhand maßgeblicher Kennzahlen evaluiert. Im Vergleich mit einem vom Autor entwickelten Kalman Filter Modell, eines Benchmark-Referenzverfahren und eines proprietären Ansatzes des Unternehmen GEVAS Software konnte das im Rahmen dieser Arbeit entwickelte Rückkopplungssystem überzeugen. Es wies sich durch eine vergleichbar gute KKR/Verfügbarkeit-Kombination und akzeptabler Rechenzeit aus.

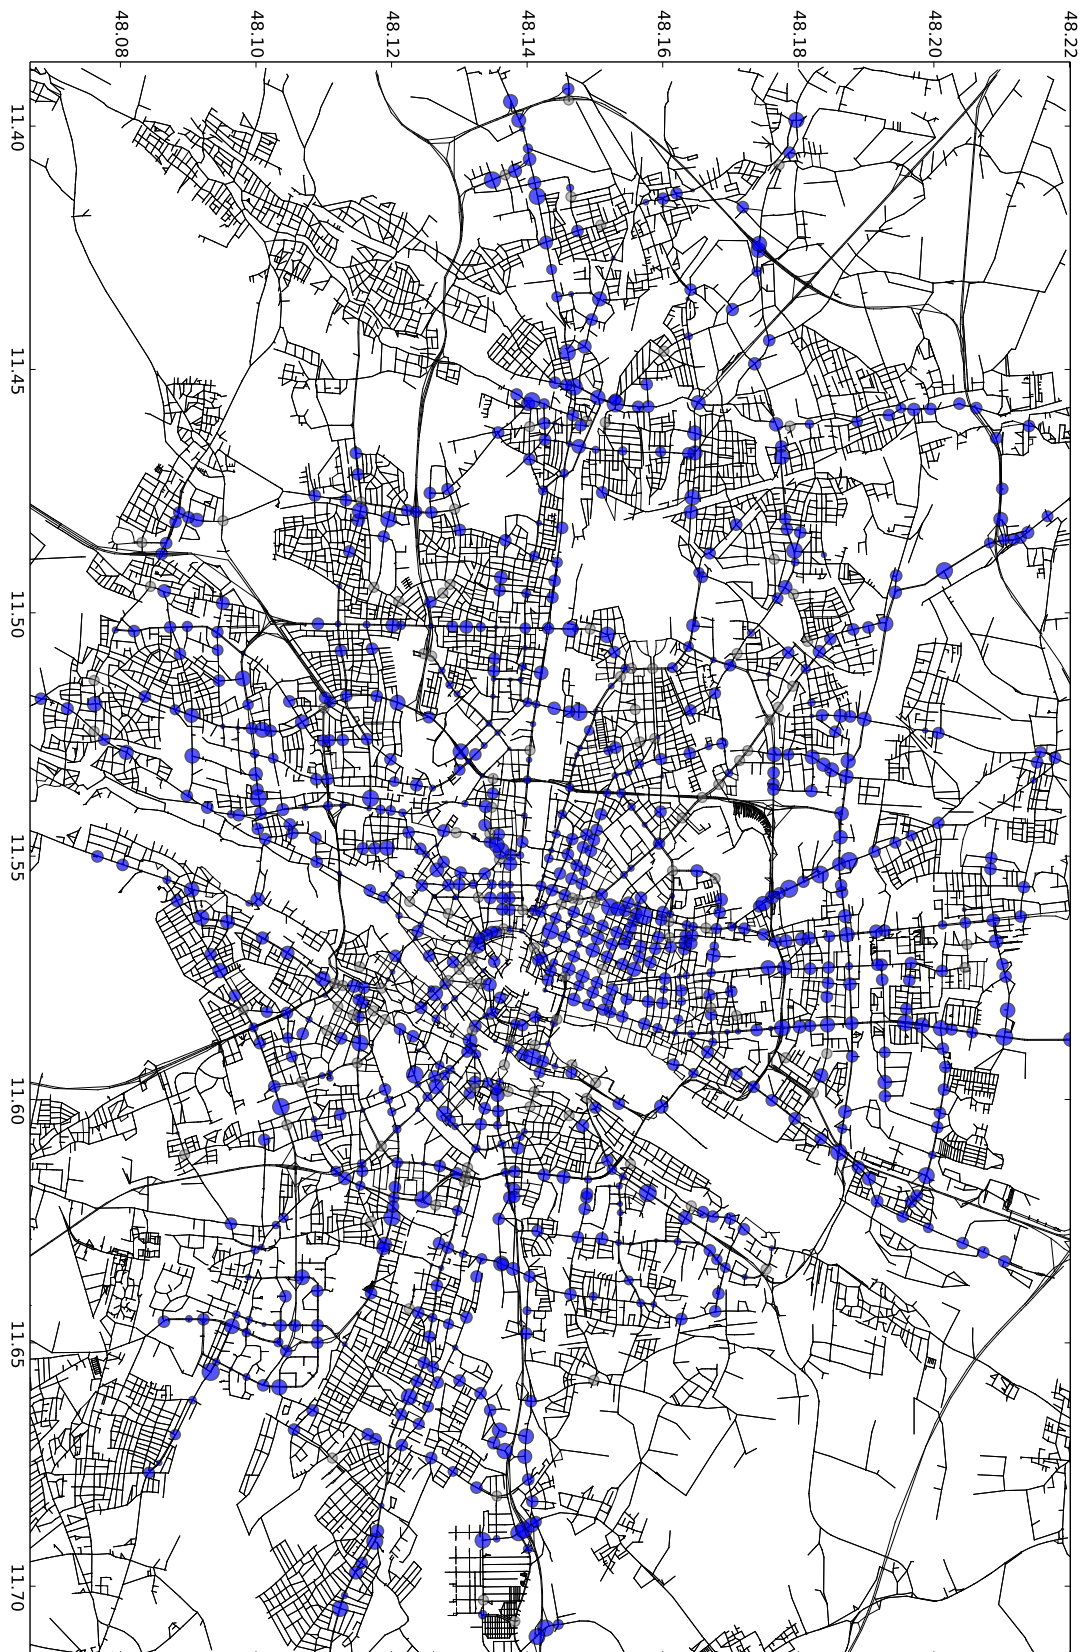


Abbildung 3.6: Schaltzeitprognosen in München: Position und Verfügbarkeit.



Abbildung 3.7: Ausblick: HMI-Vorschlag für die Nutzung der Schaltzeitprognosen mit der Kundenfunktion „Restrotanzeige“ an der Kreuzung Ingolstädterstr./Frankfurter Ring in München. Zu sehen ist ein Signalgeber mit dem Signalzustand rot und eine Restrotanzeige in einem Versuchsträger der BMW Group.

Dem Autor wurde durch die BMW Group die Möglichkeit gegeben, in einem Forschungsprojekt eine Umsetzung des Verfahrens für eine Testflotte in München zu realisieren. Auf diesem Weg konnten die Funktionen „Restrotanzeige“, „Prepare-to-Stop“, und „Grünband-Geschwindigkeitsempfehlung“ einem ausgewählten Testerkreis zur Verfügung gestellt werden. Weiterführende Arbeiten beschäftigen sich derzeit mit der Fragestellung einer geeigneten Darstellung im Fahrzeug (HMI-Konzepte), die zu einer entspannteren Fahrweise führen und Gefährdungspotentiale vermeiden.

Bei den gegenübergestellten Verfahren handelte es sich um ausschließlich statistische Modelle, die ohne Wissen über die Stellgrößen von Lichtsignalanlagen arbeiten. Dies liegt insbesondere an der Tatsache, dass Informationen über Stellgrößen oder Programmierung der Lichtsignalanlage in größerem Umfang nicht verfügbar sind - zu unterschiedlich sind die von Verkehrszentralen verwendeten Systeme. Auch eine Portierbarkeit auf andere Städte, respektive Verkehrszentralen wäre hierbei problematisch. Nicht zuletzt setzte auch die Firma GEVAS Software auf eine statistische Lösung zur Prognose zukünftiger Schaltzeiten im Testfeld Düsseldorf. Obgleich sich diese Ansätze durch eine hohe Flexibilität auszeichnen und Schaltzeitprognosen so verhältnismäßig leicht auf andere Städte übertragbar sind, ergeben sich in der Praxis oftmals erhebliche Probleme. So konnten im Ballungsraum München für etwa 57% aller Lichtsignalanlagen Schaltzeitprognosen erstellt werden. Die Firma GEVAS Software erreichte eigener Aussage zufolge mit ihrem Verfahren für Düsseldorf

ähnliche Werte. Im Fall von München lag dies zum einen daran, dass nur etwa 730 der 1100 Lichtsignalanlagen durch die Verkehrszentrale des KVR München erfasst sind. Dass dies kein Einzelfall ist, zeigt das Beispiel Stuttgart mit seinen 800 Lichtsignalanlagen, von denen „ein Großteil“ überwacht wird [67]. Ferner unterscheiden sich die Hard- und Softwarekomponenten zwischen den Städten stark, so dass jeweils Individuallösungen gefunden werden müssten. Im Testfeld München zeigte sich darüber hinaus, dass die Datenübertragung vergangener Schaltzeiten durch teilweise beträchtliche Ausfälle geprägt ist. Ursachen können hier laut KVR verlorene Signale auf dem Weg vom Verkehrsknotenpunkt in die KVR-Zentrale sein, die nach dem Prinzip „Fire-and-Forget“ versendet werden. Es ist anzunehmen, dass dieses Problem auch bei anderen Städten auftritt, zumindest jedoch nicht ausgeschlossen werden darf.

Während diese Herausforderung mithilfe intelligenter Prognosealgorithmen kompensiert werden kann, stellt die Akquisition von Daten von Dritten eine Herausforderung auf ganz anderer Ebene dar. Verkehrssteuerungszentralen haben per se zunächst kein Interesse an Ampelassistentenfunktionen in Fahrzeugen. Es überwiegen meist die rechtlichen Bedenken an einigen der Funktionen. So werden vor allem die Funktionen „Restrotanzeige“ und „Geschwindigkeitsempfehlung“ kritisch betrachtet. Diese könnten, ungünstige Visualisierung vorausgesetzt, Rasertum und Unruhe zusätzlich fördern, statt für entspannteres Fahren zu sorgen. In der Kooperationsvereinbarung der BMW Group mit dem KVR München im Rahmen der Schaltzeitprognose mithilfe vergangener Schaltzeiten wurde daher folgendes vereinbart: „In der Testphase wird zudem mit Hilfe von anonymisierten Fahrzeugdaten verifiziert, dass die neuen Funktionen das Fahrverhalten nicht ungünstig beeinflussen und Sicherheitsaspekte gewahrt bleiben.“ Diese Untersuchung ist nicht Bestandteil der vorliegenden Arbeit. Das Beispiel soll vielmehr die Sensibilität der Behörden hinsichtlich der Ampelassistentenfunktionen unterstreichen und die Schwierigkeit der Akquisition von Daten bei Städten und Kommunen hervorheben. Aus Dienstbietersicht für kundenwertige Ampelassistentenfunktionen hat dies gravierende Auswirkungen. Es müssen für jede Stadt, in der eine Ampelassistentenfunktion angeboten werden soll, Rahmenverträge mit den entsprechenden Verkehrszentralen zur großflächigen Datenüberlassung vereinbart werden. Es ist fraglich, ob eine kritische Masse erreicht werden kann. Für das Forschungsprojekt im Rahmen der vorliegenden Arbeit war das KVR München der einzige Partner, der Daten in diesem Umfang über eine Schnittstelle zur Verfügung stellte.

4 Lernen von Signalzuständen mit Floating Car Data

Mithilfe vergangener Schaltzeiten können Voraussagen über das zukünftige Schaltverhalten von Lichtsignalanlagen getätigt werden. In Kapitel 3 wurde eine skalierbare und echtzeitfähige Lösung zur großflächigen Prognose zukünftiger Signalzustände vorgestellt und evaluiert. Obgleich auf diesem Wege eine qualitativ hochwertige Vorhersage für eine breite Menge an Lichtsignalanlagen ermöglicht wird, birgt dieser Ansatz auch eine Reihe von Herausforderungen, wie sich im Testfeld München zeigte (vgl. Abschnitt 3.7). So ergeben sich hohe zeitliche und personelle Aufwände, Kontakte zu Städten und Verkehrszentralen aufzubauen und zu pflegen, sowie geeignete Rahmenverträge auszuhandeln. Oftmals ist der Zuspruch von öffentlicher Seite hinsichtlich der Ampelassistentenfunktionen aufgrund sicherheitsrechtlicher und straßenverkehrlicher Bedenken gering. Aus diesen Gründen stellt sich die Frage, ob eine Prognose zukünftiger Schaltzeiten mithilfe anderer Quellen ebenfalls möglich ist. Als besonders geeignet erscheint hier die Floating Car Data Technologie. Bereits heute werden diese Daten verwendet, um die aktuelle Verkehrssituation zu erfassen. Wie in Abschnitt 2.4 beschrieben, werden hierbei insbesondere Positions-, Geschwindigkeitsdaten und Zeitstempel zyklisch erfasst und übermittelt. Bisher ist noch ungeklärt, ob diese Technologie auch zur Rekonstruktion von Signalzuständen genutzt werden kann. Die Idee soll wie folgt beschrieben werden: Anhand des (zeitlichen) Verhaltens von Fahrzeugen im Kreuzungsbereich müssten Rückschlüsse auf das Signalverhalten von Ampeln möglich sein. Zu unterscheiden ist dabei zwischen der Betrachtung gesammelter, vergangener Daten und Echtzeit-FCD. Mithilfe einer Datenbasis gesammelter FCD für einen gewissen Zeitraum könnte das prinzipielle Signalverhalten festzeitgesteuerter Ampeln, aber auch bestimmter verkehrsabhängiger Ampeln gelernt werden. Derzeit wird davon ausgegangen, dass ca. 20% aller Lichtsignalanlagen weltweit festzeitgesteuert sind [33]. Für die USA gibt es sogar Quellen, die von einem Anteil an festzeitgesteuerten Lichtsignalanlagen von bis zu 96% sprechen [62]. Eigene Stichprobenuntersuchungen sprechen jedoch für einen geringeren Anteil. Dennoch stellt die Möglichkeit, mindestens 20% aller Lichtsignalanlagen weltweit mithilfe der Floating Car Data Technologie lernen zu können, einen hohen Anreiz für weitere Untersuchungen dar. Überdies weisen auch verkehrsabhängige Lichtsignalanlagen außerhalb der Dehnungsbereiche fixe Signalzustände auf, die sich zyklisch wiederholen (vgl. Abschnitt 2.3.3). Diese Signalzustände könnten mithilfe von FCD ebenfalls erlernt werden.

4.1 Vorveröffentlichungen

Die Kerninhalte dieses Kapitels wurden vom Autor bereits in [101] und [99] publiziert. Wie in Kapitel 1 ausführlich dargestellt, stammen die in den Veröffentlichungen und nachfolgend präsentierten Inhalte bzgl. der Idee, des Konzepts, der Theorie und Evaluation vom Autor der vorliegenden Arbeit. Ebenfalls in den Manuskripten enthalten waren die Abbildungen 4.1, 4.4, 4.6, 4.3, 4.7, 4.12 und 4.15.

4.2 FCD-basierte Ansätze in Kreuzungsbereichen

Die Idee, FCD (oder Trajektorien in einem allgemeineren Umfeld) zur Wissensextraktion zu verwenden, ist nicht neu. Weite Anwendungs- und Forschungsbereiche werden unter anderem in dem Werk *Computing with Spatial Trajectories* [38] beschrieben. Wichtige verwandte Arbeiten können in zwei Teilbereiche gruppiert werden: Einerseits empfiehlt es sich, auf wichtige Beiträge im Bereich der Verkehrsflussanalyse und Erstellung von Warteschlangenmodellen an signalisierten Verkehrsknotenpunkten einzugehen. Lichtsignalanlagen verursachen mit ihren Freigabe- und Sperrzeiten den Auf- und Abbau von Warteschlangen. Ein weites Forschungsfeld war und ist die formale und mathematische Beschreibung der zugrundeliegenden Gesetzmäßigkeiten in Form von Warteschlangenmodellen. Liegt ein genaues Modell vor, so könnte dieses zum „Reverse Engineering“ der vorliegenden Schaltzeiten genutzt werden. Ferner wird auf bestehende Arbeiten zur Schätzung von Signalzuständen mithilfe von FCD eingegangen. Sie können untergliedert werden in kinematische Ansätze, die sich die physikalischen Gesetzmäßigkeiten von Fahrzeugen zu eigen machen, der Betrachtung der Schaltzeitrekonstruktion als Optimierungsproblem und der Betrachtung als Hypothesentest.

4.2.1 Verfahren zur Verkehrsflussanalyse an Kreuzungen

Hofmann et al. stellen bereits 1994 eine Beschreibung von Verkehrsabläufen an signalisierten Knotenpunkten anhand von Beobachtungen vor [68]. Sie führten unterschiedliche Messungen durch, um speziell die durchschnittliche Reaktionszeit von Fahrern bei Signalübergängen von rot auf grün zu bemessen. Ihre Beobachtungen ergaben, dass Fahrer an erster Position vor einem Signalgeber bei einer rot/gelb-Zeit von einer Sekunde eine Reaktionszeit von 1,31 Sekunden bis zum Anfahren aufweisen. Die Folgereaktionszeiten der nachfolgenden Fahrer lag zwischen 0,78 und 1,0 Sekunden. Dieser Unterschied ist darauf zurückzuführen, dass sich Fahrer weiter hinten in der Warteschlange auf die bevorstehende Beschleunigung vorbereiten können.

Messung wie diejenigen von Hoffmann et al. stellen die Basis für Warte-

schlangenmodelle zur formellen Beschreibung des Verhaltens von Fahrern an signalisierten Kreuzungen dar. So stellen Akçelik und Besley ein lineares Warteschlangenmodell vor, anhand dessen Beschleunigungszeiten in Warteschlangen geschätzt werden können [69]. Im Rahmen ihrer Ausarbeitung stellen sie unter anderem Zusammenhänge zwischen Sättigung und Geschwindigkeit, Verkehrsflussrate und Grünstart, sowie Abbauphase von Warteschlangen und Beschleunigungsmuster her. Insbesondere werden hierfür mathematische Gleichungen und empirische Kalibrierungen vorgestellt. Besonders interessant ist im Kontext dieser Arbeit der aufgestellte Zusammenhang zwischen der Reaktionszeit eines Fahrzeuges in der Warteschlange t_x , Sättigungsrate h_s , Sättigungsgeschwindigkeit v_s und Fahrzeuglänge L_{hj} . Sie beschreiben diesen mit der Gleichung

$$t_x = h_s - 3.6 \cdot L_{hj}/v_s, \quad (4.1)$$

Ähnlich dieser Herangehensweise zur Reaktionszeitbemessung kann eine Funktion zur Grünstartschätzung aufgestellt werden.

Ramzani et al. [70] stellen eine Methode zur Schätzung von Warteschlangenprofilen an Kreuzungen auf Basis von FCD einzelner Testfahrzeuge vor. Sie legen dabei den Fokus auf die spatio-temporale Formierung und Auflösung von Warteschlangen. Mit dem Ziel einer möglichst genauen Beschreibung des zeitlichen und räumlichen Auf- und Abbaus von Warteschlangen auf Basis von vereinzelt FCD entwickeln sie ein Modell, das diese ohne die explizite Angabe von Schaltzeiten modellieren kann. Den Autoren zufolge ist das Modell weiterhin in der Lage, Überlaufeffekte von angrenzenden Kreuzungspunkten mit zu berücksichtigen und so ein realistisches Bild von urbanen Verkehrsflüssen zu zeichnen.

In einer etwas älteren Arbeit stellen Ban et al. ein Verfahren zur Schätzung von Verzögerungsmustern an signalisierten Kreuzungen anhand von gesammelten Reisezeiten vor [71]. Auch sie stellten wie bereits Hoffmann et al. [68] fest, dass Beschleunigungen eine Verzögerung nach Position aufweisen, die linear erscheint. Ihr Ansatz war es, diese linearen Zusammenhänge über ein least-squares Verfahren anzunähern. Während ihr Fokus auf der Schätzung von Verzögerungsmustern an Kreuzungen lag, konnten sie auch Schätzungen für die zugrundeliegende Umlaufzeit der betrachteten Kreuzung machen. Durch Mittelung der einzelnen geschätzten Umlaufzeiten ergab sich eine mittlere Umlaufzeit, die jedoch nie die korrekte Umlaufzeit treffen konnte. Es ergaben sich Abweichungen zwischen 0,7% und 26,9%.

Alle Verfahren haben gemein, anhand von Beschleunigungspunkten Rückschlüsse auf den Abbau der Warteschlange zu ziehen und anhand von Verzögerungspunkten den Aufbau einer Warteschlange zu schätzen. Auch eint die Ansätze, dass sie zu diesem Zweck Beobachtungen nicht nach möglichen Umlaufzeiten bündeln. Gerade dieser Aspekt ist speziell für eine Schätzung der exakten Umlaufzeit eine Lichtsignalanlage sehr vielversprechend, da anhand einer maximalen Übereinstimmung von markanten Punkten, wie etwa Beschleunigungen, gegebene Umlaufzeiten geschätzt werden könnten. Dieser

Ansatz soll im Rahmen der vorliegenden Arbeit näher untersucht werden.

Comert und Cetin stellen eine andere Herangehensweise an die Schätzung von Warteschlangen vor [72]. In ihrem Ansatz beschreiben sie eine statistische Methode zur Echtzeitschätzung von Warteschlangen an Kreuzungen mithilfe von einzelnen Testfahrzeugen, die als Sender agieren. Einen expliziten Bezug zur Lichtsignalanlage stellen sie jedoch nicht her.

4.2.2 Verfahren zum Lernen von Signalzuständen

Der Ansatz, Signalzustände anhand von FCD zu schätzen, ist noch relativ jung. Die Mehrzahl der Modelle fokussiert sich auf die Verkehrsflussanalyse und Warteschlangenschätzung im Kreuzungsbereich. Die meisten dieser Ansätze machen sich physikalische Eigenschaften wie Trägheitsmomente zur Abschätzung der Modelle zunutze. Viele der bisherigen Arbeiten zur Schätzung von Signalzuständen schlagen einen ähnlichen Weg ein. Darüber hinaus existieren Überlegungen, die sich mehr auf eine effiziente, numerische Lösung fokussieren und das Problem mehrheitlich als Optimierungsproblem ansehen.

Fayazi et al. stellen einen ersten gesamtheitlichen Ansatz zur Rekonstruktion von Lichtsignalparameter vor [51]. Dabei beschränken sich die Autoren nicht nur auf das Lernen von Grünphasen, wie es in der eher theoretischeren Arbeit von Krijger der Fall ist [73], sondern adressieren ebenfalls die Rekonstruktion der Umlaufzeit, sowie das Lernen von Programmwechseln. Ihnen stehen für ihre Untersuchungen niedrigfrequente Positionsdaten aus einer Busflotte von Next-Bus [47] in San Francisco mit Zeit- und Positionsdaten im Intervall zwischen 10 und 80 Sekunden zur Verfügung. In ihrer Arbeit fokussieren sie sich auf ausgewählte Busrouten, um die Umsetzbarkeit ihres Ansatzes nachzuweisen. Dabei handelt es sich um ein Teilstück der Van Ness Street mit sechs Kreuzungen, das von zwei Buslinien befahren wird. Insgesamt extrahieren sie 4.289 Busfahrten eines Monats, die entsprechend dem Fahrplan relativ gleichmäßig verteilt vorliegen. Weil Positions- und Zeitstempel in einem relativ großen Intervall im Bereich zwischen 10 und 80 Sekunden aufgenommen werden, verfolgen Fayazi et al. einen kinematischen Ansatz zur Rekonstruktion des Ampelverhaltens. Ihre Herangehensweise ist es, im ersten Schritt die Rotphase aus der aggregierten Verweildauer einzelner Busse bei einem Stopp an einer Kreuzung abzuleiten. Hierzu schätzen sie anhand der Busdaten die mittlere Abbremsdauer eines Busses bis zum Halt, sowie dessen mittlere Beschleunigungsdauer nach dem Start. Für eine Fahrt wird angenommen, dass diese einen Halt aufweist, wenn sich die Reisezeit in dem Bereich zweier aufgezeichneter Punkte signifikant von einer zu erwartenden Reisezeit unterscheidet. Das ermöglicht ihnen, absolute Grünstart- und Grünendzeiten zu schätzen. Im nächsten Schritt schätzen die Autoren die Umlaufzeit der jeweiligen Lichtsignalanlage. Dies erfolgt, in dem sie den Modul der Grünphasen mit minimaler Standardabweichung bestimmen. Zur Erkennung von Programmwechsel/Signalprogrammänderungen wird die gleitende mittlere Varianz der Grünphase verwendet, wie sie in der Zeitrei-

henanalyse verwendet wird [74]. Hier kommt den Autoren die Beschaffenheit ihrer Daten zugute. Da ihre Datengrundlage FCD aus einer Busflotte ist, können diese Daten als relativ gleichverteilt angesehen werden [75].

Obgleich diese Arbeit wegweisend für das automatisierte Lernen von Signalzuständen ist, wurden zentrale Fragestellungen noch nicht adressiert: Einerseits darf nicht von einer Gleichverteilung von FCD ausgegangen werden. Die der Forschungsarbeit des Autors zugrunde liegenden FCD etwa weisen eine sehr ungleichmäßige Verteilung mit einer Spitze in den Abendstunden auf (vgl. Abschnitt 2.4.2). Bei den Busdaten, die Fayazi et al. verwenden, ist dies nicht der Fall, was wiederum die Anwendung von Algorithmen des maschinellen Lernens vereinfacht. In der Arbeit von Fayazi et al. konnte daher eine vereinfachte Form der Varianzanalyse (ANOVA) [76] Programmwechsel erkennen. Allerdings verzichten die Autoren auf eine exakte Untersuchung von Erkennungsraten mit geeigneten Validierungsverfahren, wie sie z.B. in [77, Seite 147 ff.] vorgeschlagen werden. Prinzipiell gilt die Varianzanalyse als relativ robust gegenüber Abweichungen von der Normalverteilungsannahme, jedoch ist diese stets noch eine Grundannahme für ANOVA [78, Kapitel 1.1]. In diesem Fall ist diese Annahme auch vertretbar. Die NextBus-FCD scheinen relativ gleichverteilt zu sein (vgl. Abschnitt 2.4.2). So können sie für die Verteilung extrahierter Grünphasen bei korrektem Umlauf auch Gaußsche Cluster identifizieren [51]. Für die BMW-Testflottendaten kann dieser Ansatz jedoch nicht verwendet werden. Wie in Abschnitt 2.4.2 beschrieben, sind diese extrem ungleichmäßig verteilt; Tests mit diesem Ansatz brachten keine zufriedenstellende Ergebnisse. Des Weiteren ist das kinematische Modell von Fayazi et al. eine Sonderlösung, die hochspezialisiert ist, um die spärliche Informationsdichte der einzelnen Fahrten zu kompensieren. Wie jedoch in Abschnitt 2.4.2 aufgezeigt, kann von einer deutlich höheren Informationsdichte ausgegangen werden. So ist zu erwarten, dass FCD mit jeder Richtungs- und Geschwindigkeitsänderung Positionsdaten aufnehmen. Dies sollte ein Verfahren zur Rekonstruktion von Schaltzeiten weiter vereinfachen und die Qualität der Ergebnisse weiter steigern. Jedoch ist die Arbeit von Fayazi et al. ein wegweisender erster Schritt für das crowdsourcing-basierte Lernen von Signalzuständen von Lichtsignalanlagen, indem sie eindrucksvoll die Umsetzbarkeit anhand von fünf festzeitgesteuerten Lichtsignalanlagen in San Francisco unter Beweis stellen.

Kerper et al. gehen in ihrem Ansatz zur Schätzung von Signalzuständen bereits von exakten Positions- und Zeitstempeln anhand von FCD-Flottendaten aus [79]. Insbesondere setzten sie in ihrer Simulationsumgebung die exakte Ankunftszeit, sowie Zeitpunkt der Haltelinienüberquerung voraus. Eine Schätzung der Grünphase wird aus Zeiten von Haltelinienüberquerungen abgeleitet, eine Rotzeit anhand von Auftreten entsprechender Stoppzeiten. Der Grünstart wird über ein Warteschlangenmodell von Akçelik und Besley [69] geschätzt, dessen Verwendung Kerper et al. jedoch nicht genauer beschreiben. Aus diesem Grund kann nicht eindeutig geklärt werden, in welcher Form sich die Autoren das Warteschlangenmodell von Akçelik und Besley zunutze machen.

Sie evaluieren ihr Modell in der Verkehrssimulationsumgebung SUMO [80] anhand künstlich erzeugter Signalprogramme an fünf einfachen Kreuzungen (vier Kanten). In dieser Simulationsumgebung generieren sie Fahrzeuge nach einem Poisson Prozess und messen die für ihr Modell relevanten Ereignisse (Stopps, Beschleunigungen, Überfahrten). Leider konnten die Autoren ihr Modell nicht in einer realen Umgebung evaluieren. Weiterhin ist anzumerken, dass keine komplexen Kreuzungen mit mehr als vier Phasen in die Simulation einbezogen wurden.

Ein anderer Ansatz wurde in einer nicht veröffentlichten Arbeit von Daniel Kotzor bei der BMW-Group verfolgt. Er betrachtet die Schätzung von Grün- und Rotzeit als ein Optimierungsproblem, das mit einem Gradientenverfahren lösbar ist. Das zugrundeliegende Ampelmodell setzt voraus, dass es sich um eine Lichtsignalanlage mit einer festen Zykluszeit handelt, wobei davon auszugehen ist, dass Messpunkte vorliegen, die beschreiben, ob eine Lichtsignalanlage zu bestimmten Zeitpunkten rot oder grün war. Grundlage könnten hierfür z.B. Beschleunigungen und Stopps, sowie Haltelinienüberquerungen aus FCD sein. Anders als bei den bisherigen Ansätzen ist das Ziel hier, direkt die Frequenz von Grün- und Rotphasen anhand der gemessenen Punkte zu schätzen und somit mittelbar auch die Umlaufzeit zu erfassen. Um das Verhalten einer Lichtsignalanlage zu beschreiben, wird eine einfache Signumfunktion der folgenden Form angenommen: $A(t) = \text{sgn}(f(t))$, mit $f(t) = \tanh(\text{edgy} \cdot \cos(\omega t + \varphi) - \text{edgy} \cdot \gamma$. Der Parameter ω stellt die Frequenz (Ampelzykeln pro Sekunde) dar, φ die Phasenverschiebung, γ ein Maß für die Beziehung zwischen der Zeit, in der die Lichtsignalanlage den Zustand rot bzw. grün aufweist. Sie kann die Werte -1 (rot) und 1 (grün) annehmen. Der Parameter *edgy* wurde definiert, um aus der Treppenfunktion eine stetige Funktion zu generieren. Dies ist nötig, um eine Optimierung nach dem Gradientenverfahren zu ermöglichen. Optimiert wird dabei nach der least-Squares-Methode. Das Verfahren besticht durch seine Möglichkeit, sowohl die Umlaufzeit, als auch Grün- und Rotzeiten in einem Modell zu erfassen, sowie der Möglichkeit, eine Optimierung ohne ausschöpfende Suche durchzuführen. Jedoch liegt auch hier das zentrale Problem dieses Ansatzes. Zu häufig wird bei ungünstiger Wahl der Ausgangsfrequenzen lediglich ein lokales Optimum gefunden. Eine weitere Herausforderungen stellen Signalprogrammänderungen dar. Aus diesen Gründen wurde dieser Ansatz im Rahmen der vorliegenden Arbeit nicht weiter verfolgt.

Durch die Universität Eindhoven und TomTom wird im Rahmen einer Masterarbeit von Paul Krijger ein weiterer Beitrag zur Schaltzeit- und Umlaufzeitschätzung veröffentlicht [73]. Der darin beschriebene Ansatz verfolgt die Idee, die jeweiligen Haltelinienüberquerungen der Geradeausrichtungen zu untersuchen. Wenn eine korrekte Umlaufzeit gewählt ist, dürfen Fahrten in Geradeausrichtung aus beiden Hauptrichtungen nicht zu denselben Zeiträumen stattfinden, da in diesem Falle beide Fahrtrichtungen gleichzeitig grün hätten. So werden im beschriebenen Ansatz mögliche Umlaufzeiten getestet und diejenige als wahrscheinlichste ausgewählt, in der die Überschneidung von Über-

fahrtzeitpunkten beider Geradeausrichtungen minimal ist. Zu Bestimmung von Grün- und Rotphasen geht Krijger von der validen Hypothese aus, dass eine Beobachtung einer Haltelinienüberquerung zu Beginn und zum Ende der Grünphase ausreicht, um diese zu lernen. Er widmet sich in seiner sehr detailreichen und statistisch geprägten Arbeit auch der Fragestellung, nach welchen Zeiträumen, je nach Belastungsgrad und Dichte aufzeichnender Fahrzeuge, sich ein Lernerfolg einstellt. Hierbei unterscheidet er zwischen leichtem und schwerem Verkehrsaufkommen und variiert den Anteil von Fahrzeugen, die FCD aufzeichnen. In einer probabilistischen Auswertung mit der Grundannahme von Poisson-verteilten Ankunftszeiten an Kreuzungen schätzt er so mittlere Zeiten bis zu einem Lernerfolg.

4.3 Beiträge zur FCD-basierten Signalzustandsschätzung

In diesem Abschnitt wird zunächst eine theoretische Betrachtung zur FCD-basierten Signalzustandsschätzung durchgeführt. Ziel ist es, das Potential dieses Ansatzes hinsichtlich der praktikablen Einsatzes zu bewerten. Im zweiten Teil dieses Kapitels wird ein komplexer Algorithmus zur Schätzung von Signalzuständen anhand von FCD aus einer größeren Testflotte entwickelt und evaluiert. Die Evaluation erfolgt anhand von 80 ausgewählten Lichtsignalanlagen aus dem Münchner Raum, für die Signal- und Lagepläne vom KVR München zur Verfügung gestellt wurden.

4.3.1 Theoretische Betrachtung der FCD-basierten Signalzustandsschätzung

Der kritische Faktor für eine wirtschaftlichen Einsetzbarkeit des FCD-basierten Ansatzes zur Signalzustandsschätzung ist die benötigte Anzahl von aufgezeichneten FCD für eine qualitativ hochwertige Signalzustandsschätzung. So ist es nötig, zu beantworten, ob mit einer Fahrzeugflotte ausreichend Daten gesammelt werden können, um eine FCD-basierte Signalzustandsschätzung durchzuführen. Bevor Kosten, etwa durch die Sammlung von FCD aus Testfahrzeugen, Anschaffung von Hardware, bzw. Infrastruktur, oder umfangreiche Forschungsarbeiten im realen Umfeld entstehen, muss konkret beantwortet werden, wieviele FCD statistisch nötig sind, um die Signalzustände festzeitgesteuerter (und schwach verkehrabhängiger) Lichtsignalanlagen zu schätzen. Auch Krijger widmete sich für TomTom dieser Fragestellung [73], konnte jedoch nicht herausarbeiten, welche konkrete Anzahl an aufgezeichneten Haltelinienüberquerungen für eine Schätzung mit vorgegebener Qualität tatsächlich benötigt wird. Zurückzuführen ist dies auf seine korrekte Annahme der Poisson-verteilten Ankunftszeiten an Kreuzungen. Diese führt jedoch dazu, dass nur Wahrscheinlichkeitsaussagen bezüglich des voraussichtlichen Zeitraums auf Ba-

sis der geschätzten Verkehrsdichte bis zu einem Lernerfolg möglich sind - nicht jedoch über die tatsächlich benötigte Anzahl von aufgezeichneten FCD. Ziel der nachfolgenden Untersuchung ist es daher, eine belastbare Kenngröße benötigter FCD an einer Kreuzung für eine erfolgreiche Signalzustandsschätzung dieser herzuleiten. Das Verfahren und dessen Ergebnisse wurde in [101] veröffentlicht.

4.3.1.1 Annahmen

Zur Untersuchung der vorig motivierten Fragestellung werden folgende Annahmen gemacht.

- **Die betrachteten Lichtsignalanlagen sind festzeitgesteuert.** Grün- und Rotzeiten haben feste Zeitfenster, die Phasenabfolge und die Umlaufzeit sind fix.
- **Gelb existiert nicht.** Der gelbe Signalzustand entspricht rot.
- **Haltelinien sind exakt verortet.** Es liegt keinerlei Ungenauigkeit oder Rauschen bei der Position der Haltelinie vor.
- **Der Fahrer verhält sich stets korrekt.** Es gibt keinerlei Rotlichtverstöße, bereits bei gelb fährt der Fahrer nicht mehr in die Kreuzung.
- **Es liegt kein Messrauschen bei den FCD vor.** Die erhaltene Position und Geschwindigkeit aus FCD sind exakt.
- **Exakte Überfahrensinformation.** Der Zeitpunkt des Passierens einer Haltelinie ist genau erfasst.

4.3.1.2 Ziele

Für eine ordnungsgemäße Evaluation des Potentials der Signalzustandsschätzung mit FCD sind mehrere Aspekte relevant. Diese müssen genau spezifiziert werden:

- **Die Umlaufzeit muss rekonstruiert werden.** Insbesondere muss ermittelt werden, wie viele Haltelinienüberquerungen für eine Rekonstruktion der Umlaufzeit nötig sind.
- **Grün- und Rotzeiten aller Fahrverkehre müssen rekonstruiert werden.** Es muss insbesondere der Effekt der Anzahl vorliegender Haltelinienüberquerungen auf die Qualität der Schätzung von Grün- und Rotzeiten untersucht werden.
- **Eine Verteilungsanalyse der Haltelinienüberquerungen ist nötig.** Um erlauben zu können, wie viele Überfahrten notwendig sind, um

Grün- und Rotzeiten zu ermitteln, muss ein Verständnis über die Beschaffenheit der Verteilung der Zeitpunkte von Haltelinienüberquerungen bekannt sein.

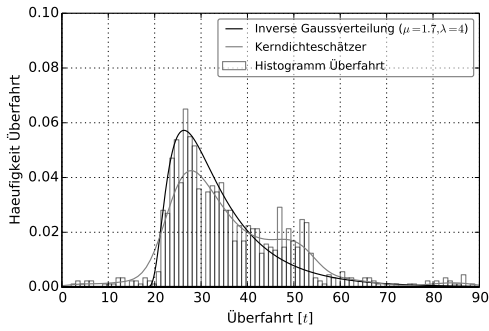
4.3.1.3 Verteilungsanalyse

Insbesondere für die Abschätzung der benötigten Überfahrten zur Rekonstruktion der Grünzeiten einzelner Fahrverkehre ist es nötig, die zugrundeliegende Verteilung von Überfahrtszeitpunkten zu kennen. Die zugrundeliegenden Testflottendaten bestehen aus 3.200 Haltelinienüberquerungen der Kreuzung Marsstraße/Seidlstr. in München. Die Signalprogrammpläne dieser (festzeitgesteuerten) Lichtsignalanlagen wurden vom KVR München bereitgestellt. Abbildung 4.1 zeigt die Charakteristik der Verteilung der ausgewerteten Daten. Es ist ein scharfer Anstieg von Haltelinienüberquerungen im ersten Drittel der Grünphase zu beobachten, gefolgt von einer Spitze und einem langsamen Abstieg bis zum Ende der Grünphase. Dies kann darauf zurückgeführt werden, dass zunächst die Warteschlange von vor der Lichtsignalanlage befindlichen Fahrzeugen abgebaut wird. Danach können sporadisch an der Kreuzung ankommende Fahrzeuge diese ohne Halt passieren. Dieses Verhalten kann durch eine inverse Gaussverteilung angenähert werden. In den Abbildungen 4.1a bis 4.1d sind Gauss-Approximationen und Kerndichteschätzer verschiedener Verteilungen von Haltelinienüberquerungen dargestellt. Die ähnlichen Verläufe der Gauss-Approximationen und dem Kerndichteschätzer untermauern die Annahme der inversen Gaussverteilung.


4.3.1.4 Rekonstruktion der Umlaufzeit: Benötigte Überfahrten

Ziel ist es, einen Schwellwert benötigter FCD für eine exakte Umlaufzeitrekonstruktion zu identifizieren, die für eine nachgelagerte Schaltzeitschätzung benötigt wird. Wurde eine korrekte Umlaufzeit geschätzt, dürfen sich Kreuzungsüberquerungen der beiden Geradeausrichtungen zeitlich nie überlagern - dies würde die Vorgaben der Kreuzungskordinierung verletzen. Es scheint folglich ein valider Ansatz zu sein, eine Reihe von Hypothesen möglicher Umlaufzeiten aufzustellen und anhand einer detektierten Verletzung (zeitliche Überlagerung von Geradeausfahrten) zu verwerfen. Im Folgenden wird zur Beschreibung diesen Sachverhalts stets von einem Widerspruch gesprochen. Im Gegenzug muss eine bestimmte Menge von FCD vorliegen, um einen hohen Grad statistischer Konfidenz für die Ablehnung einer aufgestellten Hypothese zu erreichen. Es muss die Fragestellung nach der Höhe dieser Menge an FCD beantwortet werden. Zu diesem Zweck muss der Effekt unterschiedlicher Mengen von aufgezeichneten FCD auf die Auftretenswahrscheinlichkeit eines Widerspruchs identifiziert werden.


4.3.1.4.1 Auftretenswahrscheinlichkeit eines Widerspruchs: Es sei eine Menge von Zeitpunkten von Haltelinienüberquerungen in den beiden Gerade-



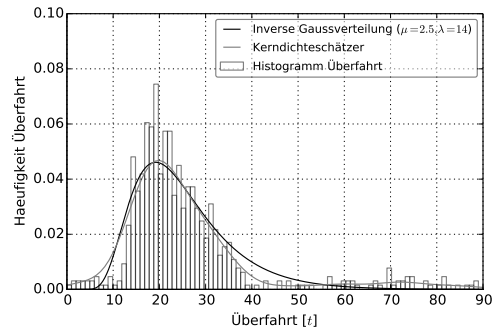
(a) Fahrverkehr 01: Grünphase Umlaufsekunde 20-52.



(b) Fahrverkehr 02, Rechtsverschiebung um 25 Zeiteinheiten zur besseren Darstellung: Grünphase Umlaufsekunde 75-8 (=10-33).



(c) Fahrverkehr 03: Grünphase Umlaufsekunde 41-67.



(d) Fahrverkehr 04, Rechtsverschiebung um 25 Zeiteinheiten zur besseren Darstellung: Grünphase Umlaufsekunde 75-8 (=10-33).

Abbildung 4.1: Kreuzung Marsstraße/Seidlstraße: Histogramme der Überfahrtszeitpunkte und Approximation durch inverse Gaussverteilung und Kerndichteschätzer (3.200 Überfahrten).

ausrichtung t_k^X, t_k^Y gegeben, wobei X und Y die Geradeausrichtungen repräsentieren. Für diese wird die relative Zeit τ_k zu einer angenommenen Umlaufzeit T errechnet mittels:

$$\tau_k = \text{mod}(t_k, T) \quad (4.2)$$

Die Umlaufzeit kann zwischen 30 und 120 Sekunden betragen: $T \in \{x \in \mathbb{N} | 0 \leq x \leq 120\}$. Aus der Menge von relativen Zeitpunkten der Haltelinienüberquerungen τ_k^X, τ_k^Y werden jeweils zwei desselben Fahrverkehrs gezogen. Diese spannen ein Intervall auf, für das bei korrekter Wahl der Umlaufzeit immer der Signalzustand grün gelten muss. Abbildung 4.2 illustriert den Vorgang wachsender Intervallgrenzen mit einer steigenden Anzahl von Überfahrten anhand einer falsch gewählten Umlaufzeit. Innerhalb der geschätzten Umlaufzeit T gibt es insgesamt $\sum_{i=1}^T 2 \cdot i$ mögliche Intervallgrößen. Diese können nur in der wie in Abbildung 4.3 illustrierten Reihenfolge angeordnet werden.




Abbildung 4.2: Vorgang wachsender Intervallgrenzen mit einer steigenden Anzahl von Überfahrten anhand einer falsch gewählten Umlaufzeit. Ein Intervall wird durch zwei Kreuzungsüberquerungen in den Richtungen X und Y aufgespannt. Im letzten Umlauf tritt ein Widerspruch, repräsentiert durch die beiden Kreise, auf.




Abbildung 4.3: Beispiel: Mögliche Kombinationen des mit zwei gemessenen Überfahrten aufgespannten Intervalls.

Die Wahrscheinlichkeit $p(\gamma)$, dass mit zwei Haltelinienüberquerungen ein Intervall der Größe γ aufgespannt wird, wird aus den möglichen Kombinationen zweier gemessenen Überfahrten ermittelt und ergibt sich zu:

$$p_\gamma = \mathbb{P}\{\text{Intervall der Größe } \gamma\} = \frac{2 \cdot (T - \gamma + 1)}{\sum_{i=1}^T 2 \cdot i} \quad (4.3)$$

bzw. nach Kürzung:

$$p_\gamma = \mathbb{P}\{\text{Intervall der Größe } \gamma\} = \frac{T - \gamma + 1}{\sum_{i=1}^T i} \quad (4.4)$$

Die Intervallgrenzen vergrößern sich mit jedem Schritt entsprechend der jeweiligen Zeitpunkte von Haltelinienüberquerungen. Daher errechnet sich die Wahrscheinlichkeit für ein Intervall der Größe γ nach n Haltelinienüberquerungen $p_{\gamma,n}$ wie folgt:

$$p_{\gamma,n} = \frac{T - \max(\gamma_n, \gamma_{n-1}) + 1}{\sum_{i=1}^T i} \quad (4.5)$$

Die Wahrscheinlichkeit eines Widerspruchs $p_{\gamma,n}^u$ zweier unterschiedlicher Wahrscheinlichkeitswerte für Intervalle nach n Haltelinienüberquerungen ergibt sich


zu:

$$p_{\gamma,n}^u = \left(\max(\max(\gamma_n^Y, \gamma_{n-1}^Y), \max(\gamma_n^X, \gamma_{n-1}^X)) + 2 \cdot \min(\max(\gamma_n^X, \gamma_{n-1}^X), \max(\gamma_n^Y, \gamma_{n-1}^Y)) \right) / T \quad (4.6)$$

4.3.1.4.2 Vergleich mit Simulationsergebnissen: Zur Berechnung der stochastischen Wahrscheinlichkeit werden Hypothesen für Umlaufzeiten im Intervall [30, 120] herangezogen. In Abbildung 4.4a ist der Verlauf der entsprechenden Verteilungsfunktion dargestellt. Ebenfalls angetragen ist hier die tatsächliche Häufigkeit eines Widerspruchs in einer Simulationsumgebung (grüne Marker). Dabei wurde eine einfache Kreuzung mit den folgenden Parametern simuliert: Grünstart_X = 11, Grünende_X = 20, Grünstart_Y = 21, Grünende_Y = 89, Umlaufzeit = 90. Simuliert wurden Haltelinienüberquerungen sowohl unter der Annahme einer Normalverteilung, als auch unter der Annahme einer inversen Gaussverteilung der Haltelinienüberquerungen. Um statistische Konfidenz zu erlangen, wurden jeweils 50.000 Überfahrten generiert. Es ist zu beobachten, dass die simulierten Häufigkeitsverteilungen und die Wahrscheinlichkeitsverteilung $p_{\gamma,n}^u$ einen identischen Verlauf aufweisen, was die Korrektheit der hergeleiteten Formel 4.6 bestätigt. Auch die beiden Häufigkeitsverteilungen unter der Annahme unterschiedlicher zugrundeliegender Verteilungsfunktionen haben identische Verläufe, was zu dem Schluss führt, dass die Verteilung von Haltelinienüberquerungen keinen Einfluss auf die benötigte Anzahl von FCD zur verlässlichen Detektion einer falschen Umlaufzeithypothese haben. In allen drei Szenarien ist die Existenz von 40 Haltelinienüberquerungen ausreichend für eine Erkennung einer falschen Umlaufzeithypothese mit einer Konfidenz von 0,999. Zu bemerken sei, dass die Häufigkeitsverteilungen nie den Wert 1 annehmen. Dies ist der Tatsache geschuldet, dass die korrekte Umlaufzeithypothese nie einen Widerspruch aufweisen kann.

4.3.1.4.3 Detektion der korrekten Umlaufzeit (Korrektklassifikationsrate): Die Detektion eines Widerspruchs gibt per se keinen Aufschluss über die Wahrscheinlichkeit der Detektion der tatsächlichen Umlaufzeit. Lediglich bei einer Wahrscheinlichkeit eines Widerspruchs für eine falsche Umlaufzeit von 1 könnte stets die korrekte Umlaufzeit entdeckt werden. Der Anteil von Detektion der korrekten Umlaufzeit muss anhand der Korrektklassifikationsrate (KKR) ermittelt werden. Sie gibt den Anteil der korrekt klassifizierten Objekte an (vgl. hierzu Abschnitt 3.3).

Die KKR der Umlaufzeit könnte einen anderen Verlauf als die Detektion eines Widerspruchs nach Formel 4.6 aufweisen. Tatsächlich zeigen Simulationen, dass diese nicht durch eine Exponentialverteilung angenähert werden kann, sondern vielmehr die Form einer logistischen Funktion aufweist (vgl. Abbildung 4.4b). Dies ist darin begründet, dass für eine eindeutige Erkennung immer eine gewisse Grundmenge an Überfahrten zur Verfügung stehen muss.



(a) Stochastische Wahrscheinlichkeit der Detektion einer falschen Umlaufzeithypothese nach Formel 4.6, Häufigkeiten eines Widerspruchs (Simulationen). (b) Wahrscheinlichkeit der korrekten Klassifikation einer Umlaufzeithypothese (50.000 Simulationen) und Approximation durch die logistische Funktion.

Abbildung 4.4: Stochastische Wahrscheinlichkeit und empirische Häufigkeit der Detektion einer falschen Umlaufzeithypothese und Häufigkeitsverteilung der eindeutigen Detektion der korrekten Umlaufzeit.

Für den Schwellwert einer korrekten und eindeutigen Erkennung der richtigen Umlaufzeit hat dies jedoch keine Auswirkungen: Mit 40 verfügbaren Kreuzungsüberquerungen ist eine KKR von über 0,999 erreicht.

4.3.1.4.4 Anteil eindeutiger und gegenläufiger Fahrverkehre: Die in Abbildung 4.4b dargestellten Simulationsergebnisse beruhen auf einer einfachen Kreuzungstopologie mit zwei Fahrverkehren. Die Mehrheit der Kreuzungen ist jedoch komplexer. Während bei kleinen Kreuzungen meist nur zwei Fahrverkehre (für Geradeaus-, Links- und Rechtsabbieger) existieren, gibt es an komplexeren Kreuzungen mehrere Fahrverkehre. So ist es möglich, dass Geradeausrichtungen nur in einem kleinen Teil der Umlaufzeit geschaltet sind. Allerdings sind diese beiden Fahrverkehre die einzigen, die definitiv zu unterschiedlichen Zeiten bedient werden. Aus diesem Grund wurde in einer weiteren Simulation untersucht, welche Auswirkungen der zeitliche Anteil von Geradeausrichtungen an der Umlaufzeit auf die KKR haben. Grafik 4.5 illustriert diesen Sachverhalt. In der zugrundeliegenden Simulation wurden die Kreuzungsparameter sukzessive verändert und so der Zeitanteil von Geradeausrichtungen an der Umlaufzeit in insgesamt 500.000 Simulationen im Intervall $[0, 95; 0, 51]$ verändert. Es sei angemerkt, dass bei einem Zeitanteil der Geradeausrichtungen von weniger als 0,51 die Umlaufzeit nicht mehr eindeutig bestimmbar ist, da auch die Umlaufzeithypothese $T/2$ niemals zu einem Widerspruch führen wird. Es ist ersichtlich, dass der Anteil der Fahrverkehre in Geradeausrichtung eine hohe Auswirkung auf die benötigte Anzahl von Überfahrten einer Kreuzung für die eindeutige Bestimmung der Umlaufzeit hat. So sind für eine 95 prozentige Konfidenz der Erkennung der eindeutigen und korrekten Umlaufzeit bei

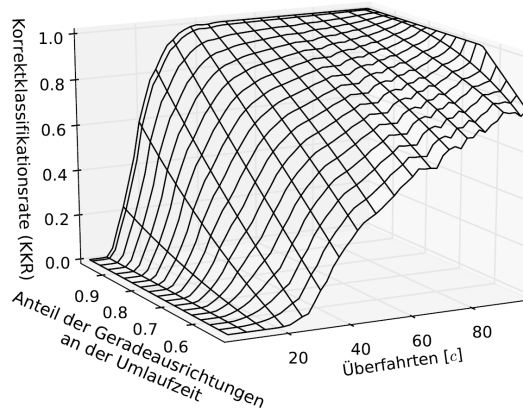


Abbildung 4.5: Häufigkeitsverteilung der eindeutigen Detektion der korrekten Umlaufzeit bei variierendem Anteil der Fahrverkehre an der Umlaufzeit.

einem Anteil der Geradeausrichtungen von 0.9 nur 40 Überfahrten nötig, bei einem Anteil von 0.7 sind bereits 100 Überfahrten zu erfassen.

4.3.1.5 Rekonstruktion der Grünzeiten: Benötigte Überfahrten

4.3.1.5.1 Auftretenswahrscheinlichkeit einer Haltelinienüberquerung:

Zur Beschreibung der Verteilung von Haltelinienüberquerung wird eine inverse Gaussverteilung angenommen (vgl. Abschnitt 4.3.1.3). Auch wird der Verlauf der zugrundeliegenden Verteilung unabhängig von der Grünphase eines Fahrverkehrs angegeben. Dies ist dann zulässig, wenn Zeitpunkte der Überfahrten anteilig zur Grünphase angegeben werden und der Verlauf der angenommenen Verteilung von Überfahrten ebenfalls hinsichtlich des Intervalls der Grünzeit normalisiert wird.

Um die Grünzeiten eines Fahrverkehrs exakt zu bestimmen, muss eine Überfahrt zum Grünstart und eine Überfahrt zum Grünende erfasst werden. Die Wahrscheinlichkeit, zum Beginn der Grünphase eine Überfahrt zum Umlaufzeitpunkt τ zu beobachten, werde $p_{g,s}$, die Wahrscheinlichkeit, zum Ende der Grünphase eine Überfahrt zu beobachten, $p_{g,e}$ bezeichnet. Für diese Werte ergibt sich:

$$p_{g,s} = \mathbb{P}(\Upsilon \leq \tau) = F(\tau) = \int_{-\infty}^{\tau} f(u)du \quad (4.7)$$

$$p_{g,e} = \mathbb{P}(\Upsilon \geq \tau) = 1 - F(\tau) = 1 - \int_{-\infty}^{\tau} f(u)du, \quad (4.8)$$

wobei Υ („relativer Zeitpunkt der Überfahrt“) eine Zufallsvariable sei und die inverse Gaussfunktion definiert ist als:

$$f(\tau) = \left(\frac{\lambda}{2\mu\tau^3} \right)^{\frac{1}{2}} e^{-\frac{\lambda(\tau-\mu)^2}{2\mu^2\tau}} \quad (4.9)$$

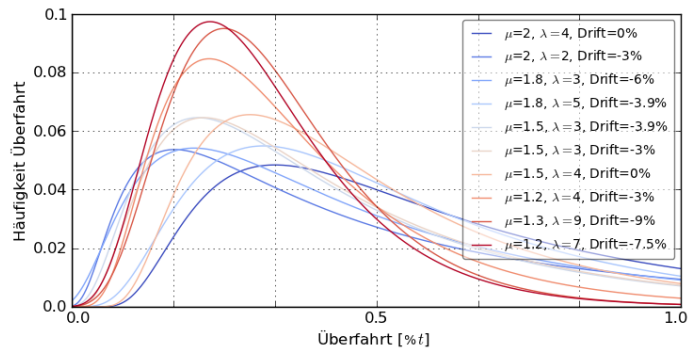


Abbildung 4.6: inverse Gaussverteilung der Zeitpunkte von Überfahrten (relativ zur Grünzeit eines Fahrverkehrs) mit unterschiedlichen Parametern.

und

$$F(\tau) = \phi\left(\sqrt{\frac{\lambda}{\tau}}\left(\frac{\tau}{\mu} - 1\right)\right) + e^{\frac{2\lambda}{\mu}} \phi\left(-\sqrt{\frac{\lambda}{\tau}}\left(\frac{\tau}{\mu} + 1\right)\right) \quad (4.10)$$

wobei ϕ die standard-Gaussverteilung ist. Damit ergibt sich für die Anzahl der Überfahrten n , mit einem Konfidenzniveau K genau den Start einer Grünphase zu beobachten:

$$\begin{aligned} F(\tau)^n &= K \\ n &= \frac{\ln(K)}{\ln(F(\tau))} \end{aligned} \quad (4.11)$$

Analog ergibt sich für die Anzahl der Überfahrten zum Ende der Überfahrt:

$$\begin{aligned} 1 - F(\tau)^n &= K \\ n &= \frac{\ln(1 - K)}{\ln(F(\tau))} \end{aligned} \quad (4.12)$$

4.3.1.5.2 Analyse mit unterschiedlichen Parametersätzen: Für die Bewertung der Anzahl nötiger Haltelinienüberquerungen zur Rekonstruktion der Grünzeiten individueller Fahrverkehre wurden unterschiedliche realistische Parametersätze entworfen. Zunächst wurden verschiedene inverse Gaussverteilungen für Zeitpunkte von Haltelinienüberquerungen angenommen. Deren Verläufe sowie Parameter sind in Abbildung 4.6 dargestellt. μ und λ stellen dabei die jeweiligen Parametrisierungen und „Drift“ die Verschiebung auf der x-Achse dar. Charakteristisch für die Verteilung der Überfahrtszeitpunkte ist stets ein steiler Anstieg der anteiligen Überfahrten im ersten Drittel der Grünzeit. Begründet werden kann dies durch die Überquerung der sich in der Warteschlange befindlichen Fahrzeuge. Darauf folgt ein konstanter, weniger steiler Abfall der Häufigkeit von Haltelinienüberquerungen. Die Ausprägung des Kurvenverlaufes, Scheitelpunkt und dessen Position können aber variieren. Dies spiegelt

sich in den unterschiedlichen Verläufen der inversen Gaussfunktion mit unterschiedlichen Parametersätzen in Abbildung 4.6 wider.

Im Folgenden wird für diese Parametersätze die Wahrscheinlichkeit der Beobachtung einer Überfahrt zu Beginn und zu Ende der Grünphase bestimmt. Abbildung 4.7 beschreibt die Wahrscheinlichkeit der erfolgreichen Beobachtung einer Überfahrt zu Beginn einer Grünphase in Abhängigkeit dieser Parameter. Abbildungen 4.7a, 4.7c und 4.7e beschreiben die Wahrscheinlichkeit der erfolgreichen Beobachtung einer Überfahrt zum Beginn einer Grünphase in Abhängigkeit der obig genannten Parameter. Abbildungen 4.7b, 4.7d und 4.7f illustrieren entsprechend die Wahrscheinlichkeit der erfolgreichen Beobachtung einer Überfahrt zum Ende einer Grünphase. Es wird dabei zwischen den Zeitbereichen 6,6% ($\sim 2s$), 13,3% ($\sim 4s$) und 20% ($\sim 6s$) unterschieden. Im Vergleich der Abbildungen 4.7a und 4.7b wird ersichtlich, dass eine Beobachtung einer Haltelinienüberquerung in den letzten beiden Sekunden deutlich wahrscheinlicher ist, als in den ersten beiden Sekunden. Dies kann auf die Reaktionszeit zwischen Grünstart und Beschleunigung von an der Kreuzung befindlichen Fahrzeugen zurückgeführt werden, wie sie in Abschnitt 4.2.1 beschrieben wurde. Auch fällt auf, dass eine Überfahrtsbeobachtung in den ersten beiden Sekunden nach dem Grünstart eher unwahrscheinlich ist. Auch mit 400 Haltelinienüberquerung stellt sich bei keinem der angenommenen Verläufe eine Erfolgswahrscheinlichkeit von mehr als 0,18 für die Beobachtung einer Überfahrt ein (vgl. Abbildung 4.7a). Eine Überfahrt in den letzten beiden Sekunden ist für die meisten angenommenen inversen Gaussverteilungen wahrscheinlich. Die Wahrscheinlichkeit für eine Beobachtung im ersten Siebtel der Grünphase ist bei 400 Überfahrten für vier der eingeführten Kurvenverläufe höher als 0,7. Eine Beobachtungswahrscheinlichkeit im letzten Siebtel liegt für 7 von 10 Kurven bei mehr als 0,8. Im ersten Fünftel, respektive im letzten Fünftel, liegt die Beobachtungswahrscheinlichkeit bereits bei 0,95, bzw. 0,94.

4.3.2 Bewertung der theoretischen Betrachtung

In der Potentialabschätzung einer FCD-basierten Signalzustandschätzung konnte unter Annahme eines einfachen Modells und idealen Bedingungen eine statistische Bewertung des Zusammenhangs zwischen Beobachtungen (in Form von Haltelinienüberquerungen) und Qualität der Schaltzeitrekonstruktion getätigt werden. Hier zeigte sich im Ergebnis, dass ca. 40 Haltelinienüberquerungen je beider Geradeausrichtungen nötig sind, um die korrekte Umlaufzeit innerhalb eines Intervalls mit einer KKR von mehr als 0,99 zu schätzen. Geht man von mehreren Programmwechseln im Tagesverlauf aus, so wäre eine valide Folgerung, einen Zielwert von 40 Überfahrten in jedem Stundenintervall für jede der beiden Geradeausrichtungen zu empfehlen. In dieser sehr restriktiven Schätzung wird davon ausgegangen, dass Programmwechsel prinzipiell zu jeder Stunde möglich sind, was zu einer Menge von $2 \cdot 960 = 1.920$ benötigten Haltelinienüberquerungen führen würde, um eine Schaltzeitschätzung in gerin-

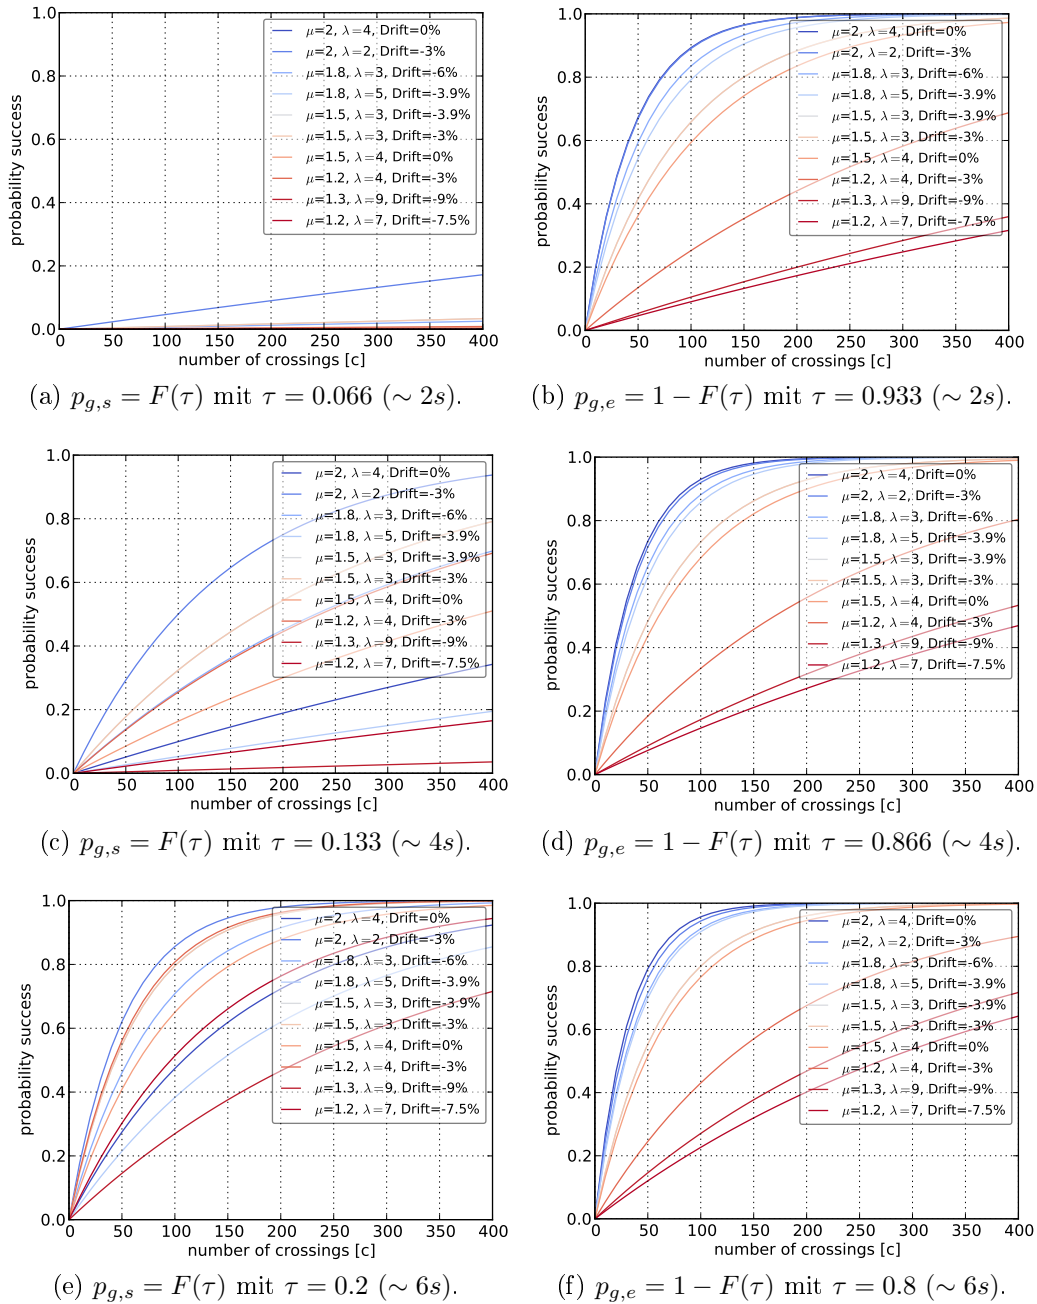


Abbildung 4.7: p_{Erfolg} für eine Beobachtung einer Haltelinienüberquerung zum Beginn der Grünphase ($p_{g,s}$) bzw. zum Ende der Grünphase ($p_{g,e}$).

ger Qualität für den gesamten Tag durchführen zu können. Diese geschätzten Zielwerte aufzuzeichnender Daten wurden hinsichtlich Erreichbarkeit von unternehmerischer Seite (BMW Group) als realisierbar eingestuft.

Aus wissenschaftlicher Sicht sollen die Ergebniswerte ausschließlich als Anhaltspunkt einer erreichbaren Zielgröße für die Qualität der Schaltzeitschät-

zung dienen. Es ist offensichtlich, dass der volle Informationsgehalt der Daten mit seiner Vielzahl statistischer Variablen noch nicht ausgeschöpft wurde.

4.3.3 FCD-basierte Signalzustandschätzung im Realumfeld: Lernen der Umlaufzeit

Mithilfe der theoretischen Betrachtung zur Rekonstruktion und Prognose zukünftiger Schaltzeiten konnte das Potential von FCD für das Lernen von Signalisierungszuständen an Lichtsignalanlagen aufgezeigt werden. Mit dem Wissen, dass mindestens 20% aller Lichtsignalanlagen weltweit festzeitgesteuert sind, zudem noch weitere 20% geringfügig verkehrsabhängig und somit ebenfalls mit FCD lernbar sind, werden die Möglichkeiten dieses Ansatzes offensichtlich. Die im Labor erzeugten Ergebnisse geben folglich Anlass, weitere Forschungen durchzuführen, die sodann im realen Umfeld bestätigt werden müssen. Die zentrale Herausforderung liegt hierbei in den Ungenauigkeiten (Rauschen) der im Fahrzeugumfeld generierten Daten. GPS-Sensordaten, die mittels der FCD-Technologie aufgezeichnet werden, können Ungenauigkeiten von wenigen Zentimetern bis hin zu mehreren Metern haben. Dieses Rauschen wird in der Literatur als gaussverteilt betrachtet [38]. Für das Lernen von Schaltzeiten ist überdies die Kenntnis über die Position der entsprechenden Haltelinie unabdingbar. Auch diese sind einem Rauschen unterworfen. Es kann gefolgert werden, dass die im Labor hergeleiteten Kennzahlen nötiger Kreuzungsüberfahrten in der Praxis mit dem vorgestellten Verfahren deshalb wohl nicht erreicht werden können. Es muss ein Verfahren entwickelt werden, das in der Lage ist, die beschriebenen Ungenauigkeiten zu kompensieren, aber auch eine möglichst hohe Genauigkeit der gelernten Parameter bei gleichzeitig wenig aufgezeichneten Fahrten aufzuweisen. Eine Lösung hierzu ist, den Informationsgehalt von den FCD noch weiter auszuschöpfen. So kann aus den aufgezeichneten Fahrten nicht nur der Zeitpunkt einer Haltelinienüberquerung abgeleitet werden, sondern das gesamte Verhalten eines Fahrers im Kreuzungsbereich analysiert werden. Der nachfolgende Abschnitt ist wie folgt aufgebaut: Zunächst wird die vorhandene Datengrundlage beschrieben und deren (Vor-)Verarbeitung erläutert. Sodann werden verschiedene Verfahren zur Rekonstruktion der Umlaufzeit vorgestellt und anschließend vergleichend evaluiert. Es sei an dieser Stelle vorweggenommen, dass das Lernen der korrekten Umlaufzeit der herausfordernde Aspekt beim Lernen vom zukünftigen Schaltzeiten ist und sich daher ein Großteil der hier vorgestellten Forschungsarbeit auf diesen Aspekt fokussiert. Im Anschluss werden Verfahren zum Lernen des Grünstartes und Grünendes vorgestellt und bewertet. Weite Teile der Verfahrens und deren Ergebnisse wurden durch den Autor in [99] veröffentlicht.

4.3.3.1 Datengrundlage

Floating Car Data: Zur Untersuchung im realen Umfeld liegen ca. 400.000 aufgezeichnete Fahrten aus einer Testflotte vor. Eine Fahrt f_n aus einer Menge von Fahrten F , $f_i \in F$ kann dargestellt werden als eine Folge von Tripeln t_i Ortpunkten, die mit einem Zeitstempel versehen sind: $f_i = ((\lambda_1, \delta_1, t_1), (\lambda_2, \delta_2, t_2), \dots, (\lambda_n, \delta_n, t_n))$. Dabei stellen λ_i, δ_i die geographischen Koordinaten des sich bewegenden Fahrzeuges zum Zeitpunkt t_i dar. Diese Darstellung kann weiter vereinfacht werden, nämlich über die Repräsentation der Fahrt durch Ortpunkte, die mit einem Zeitstempel versehen wurden: $f_i = (p_0, p_1, \dots, p_n)$, wobei $p_i = (\lambda_i, \delta_i, t_i)$ der Positionspunkt des Fahrzeuges zum Zeitpunkt t_i ist.

Für das Lernen von Schaltzeiten auf Basis von FCD ist lediglich das Fahrverhalten im jeweiligen Kreuzungsbereich relevant. Hierzu wird ausgehend von der Haltelinie eines jeden in die Kreuzung einmündenden Links ein Radius r gezogen. Vereinfachend wird der Schnittpunkt der Haltelinie h mit der in die Kreuzung einmündenden Kante des zugrundeliegenden Graphen verwendet. Die Koordinaten der Haltelinie h werden dabei als λ_h, δ_h bezeichnet. Es schneiden jeweils der in die Kreuzung einmündende und von dieser ausgehende Link diesen Radius. Diese Schnittpunkte mit dem gezogenen Radius können zusammengefasst werden zu einer Eingangsklasse e und Ausgangsklasse a . Für jede aufgezeichnete Fahrt $f_i \in F$ werden Teilfolgen f_i^z aller mit Zeitstempel versehenen Ortpunkten p_i gebildet, für die gilt: $f_i^z : \iff \exists h : \forall i : \|(\lambda_i, \delta_i) - (\lambda_h, \delta_h)\|_2 \leq r$. Die Menge der sich ergebenden Teilpfade $f_i^z \in F$ muss entsprechend des eingehenden Links und des ausgehenden Links klassifiziert werden. Dies erfolgt durch die Berechnung der rechtsweisenden Peilung θ (Winkel zwischen rechtsweisend Nord und Fahrtrichtung) bei Eintritt e einer Fahrt in den betrachteten Radius r , respektive bei Austritt a . Diese wird berechnet wie folgt:

$$\theta = \text{atan2}(\sin \Delta\lambda \cdot \cos \delta_2, \cos \delta_1 \cdot \sin \delta_2 - \sin \delta_1 \cdot \cos \delta_2 \cdot \cos \Delta\lambda) \quad (4.13)$$

Dabei stellt $\Delta\lambda$ die Differenz der Längengrade λ_1 und λ_2 und δ_i den Breitengrad eines Positionspunktes p_i dar. Hierbei werden die jeweiligen beiden ersten und letzten Punkte im gewählten Radius um die Haltelinie gewählt, um den jeweiligen Eintritts- und bei Austrittswinkel θ_e und θ_a zu bestimmen. Aus einer Kartendatenbasis werden die entsprechenden Kanten $(u, v) \in E$ um den betrachteten Kreuzungsmittelpunkt extrahiert und deren rechtsweisende Peilung $\theta_{(u,v)}$ ebenfalls berechnet. Ein Teilpfad wird sodann einer Eingangs-/Ausgangsklasse $F_{e,a}^z$ wie folgt hinzugefügt:

$$F_{e,a}^z := \{f_i^z \mid \theta_{(u,v)_e} - th_\theta \leq \theta_e \leq \theta_{(u,v)_e} + th_\theta \wedge \theta_{(u,v)_a} - th_\theta \leq \theta_a \leq \theta_{(u,v)_a} + th_\theta\} \quad (4.14)$$

Hierbei stellt th_θ einen Schwellwert in Winkelgrad dar. In der vorliegenden Arbeit wurde für th_θ der Wert 20° gewählt. Eine Visualisierung exemplarischer FCD mit diesen Vorverarbeitungsschritten ist in Abbildung 4.8 zu sehen.

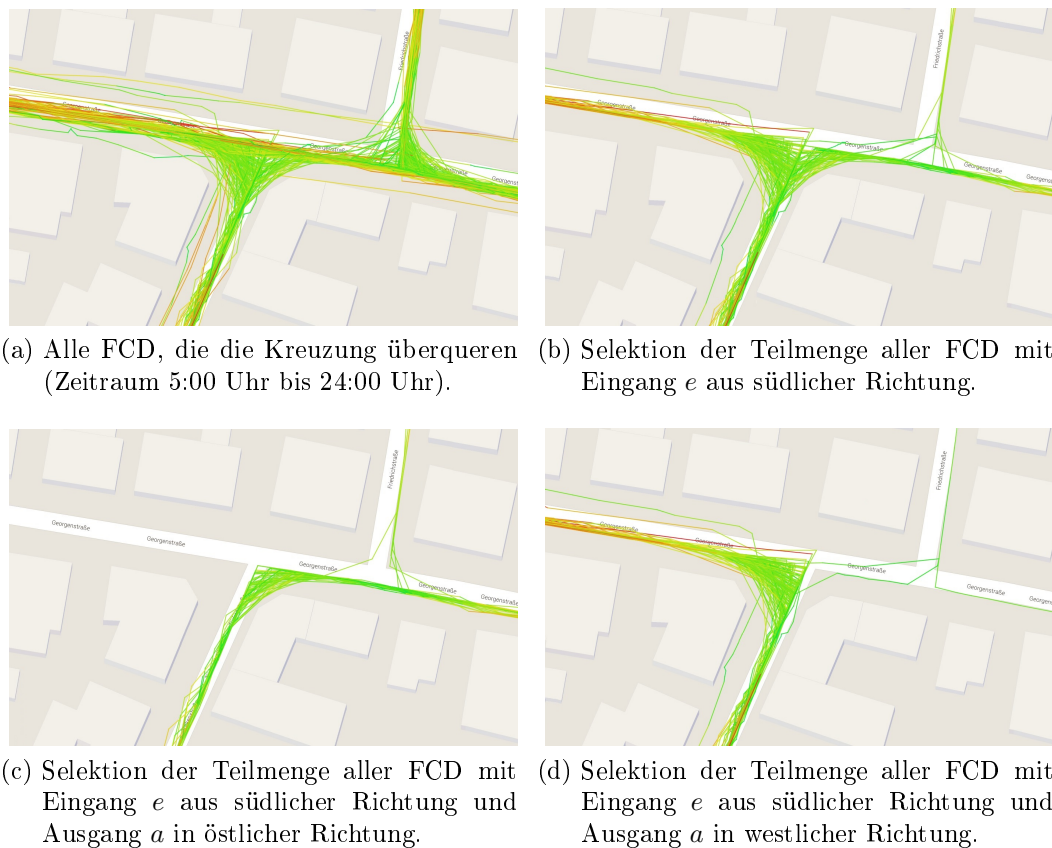


Abbildung 4.8: FCD im Kreuzungsbereich. Selektion aller FCD, die die Kreuzung Georgenstr./Türkenstr. überqueren. Die Geschwindigkeitsprofile sind in verschiedenen Färbungen von 0 km/h (grün) bis 50 km/h (rot) visualisiert. Deutlich erkennbar sind die Ungenauigkeiten in der Positionierung, insbesondere bei den Abbiegevorgängen.

Im Testfeld liegen neben den aufgezeichneten Fahrten auch Kartenmaterial und Haltelinienpositionen vor. Da die Information über Haltelinienpositionen in bestehenden Kartenmaterialien meist nicht vorhanden ist, müssen die Haltelinien zunächst in einem semiautomatisierten Prozess gelernt werden. Ein Ansatz, der im Rahmen der Forschungsarbeit des Autors verfolgt wurde, ist die Extraktion von Haltelinienpositionen aus Satellitenbildern [102]. Ein anderer Ansatz ist die FCD-basierte Extraktion von Haltelinien [81]. Beide Verfahren können nur grobe Positionsschätzungen machen. Das satellitenbasierte Verfahren weist einen Fehler im Bereich der geographischen Verortung dieser Bilder auf. Im vorliegenden Fall wurde teilweise auf die Satellitenbilder von Google Earth zurückgegriffen, für die im Jahr 2013 eine Genauigkeit von 1.59 Meter (RMSE) angegeben wurde [82], aber auch grobe Abstandsschätzungen zum Kreuzungsmittelpunkt wo eine satellitenbasierte Bestimmung nicht möglich war. Die Autoren des FCD-Ansatzes geben einen Fehler zwischen 2.2 und 7 Meter an [81].

Lichtsignalanlagen und Signalprogramme: Vom KVR München wurden verkehrstechnische Unterlagen zu Lichtsignalanlagen in München bereitgestellt. Diese beinhalten zum einen topologische Lagepläne, in denen Haltelinien, Signalgeber, Signalgruppen und Fahrverkehre verortet sind. Abbildung 2.4 stellt einen topologischen Lageplan für eine Kreuzung in München beispielhaft dar. Darüber hinaus wurden durch das KVR München Festzeitsignalprogrammpläne für festzeitgesteuerte Lichtsignalanlagen, aber auch Festzeitersatzprogramme für verkehrsabhängige Lichtsignalanlagen zur Verfügung gestellt. Diese Ersatzprogramme stellen im Fall München laut dem Kreisverwaltungsreferat ein Backup-Signalprogramm dar, welches bei Störungen, etwa von Messstellen, Einsatz findet. Es bildet darüber hinaus auch den Rahmen für verkehrsabhängige Steuerungsverfahren. Würde eine Anlage aufgrund hohen Verkehrsaufkommens stets an die Adaptionsgrenzen des verkehrsabhängigen Programmes stoßen, so entspräche der Ablauf dem des hinterlegten Festzeitersatzprogrammes. Zur Untersuchung des FCD-basierten Ansatz zur Schaltzeitrekonstruktion wurden insgesamt 80 Münchner Lichtsignalanlagen ausgewählt, 48 davon festzeitgesteuert und 32 davon schwach verkehrsabhängig. Abbildung 4.9 stellt die Positionen der festzeitgesteuerten und verkehrsabhängigen Lichtsignalanlagen dar. Dabei sind festzeitgesteuerte Lichtsignalanlagen lila eingefärbt, verkehrsabhängige Lichtsignalanlagen in blau dargestellt. Die Wahl der 32 verkehrsabhängigen Lichtsignalanlagen erfolgte anhand der zufälligen Betrachtung von Signalmustern. Diese 32 Lichtsignalanlagen wiesen nur geringfügige Signalanpassungen auf und scheinen daher für eine Analyse mithilfe von FCD geeignet. Aus der Menge der festzeitgesteuerten Lichtsignalanlagen wurden 48 ausgewählt, die keinen weiteren Einflüssen (etwa ÖPNV-Priorisierung oder Bedarfssteuerung) unterworfen sind.

4.3.3.2 Motivation

Ein Lernalgorithmus soll eine hohe Toleranz hinsichtlich Rauschen, also Ungenauigkeiten in der Haltelinienverortung, als auch bei den aufgenommenen FCD, ausweisen. Dies ist für die meisten Verfahren zur Rekonstruktion der Schaltzeiten sicherlich der Fall. Eine hohe Konfidenz einer Aussage kann aber unter Umständen erst bei einer beträchtlichen Menge von FCD getätigt werden. Die Notwendigkeit großer Datenmengen wird dann zur Herausforderung, wenn für eine Lichtsignalanlage während des Tages Programmwechsel bestehen. Typischerweise sind Lichtsignalanlagen unabhängig davon, ob festzeitgesteuert oder verkehrsabhängig, so programmiert, ihre Freigabe- und Sperrzeiten und gegebenenfalls auch ihre Umlaufzeit zu ändern, um den Verkehrsdurchsatz zu erhöhen (vgl. Abschnitt 2.3). Um einzelne Programme mit einer hohen Genauigkeit voneinander separieren zu können, muss für jedes der Programme und insbesondere zum Zeitpunkt des Wechsels eine „ausreichende“ Menge von FCD vorliegen. Der Begriff „ausreichend“ ist in diesem Kontext als Menge von Überfahrten zu verstehen, mit der eine korrekte Umlaufzeit mit hoher Konfidenz ($>0,999$) erlernt werden kann. Im theoretischen Teil dieses Abschnittes

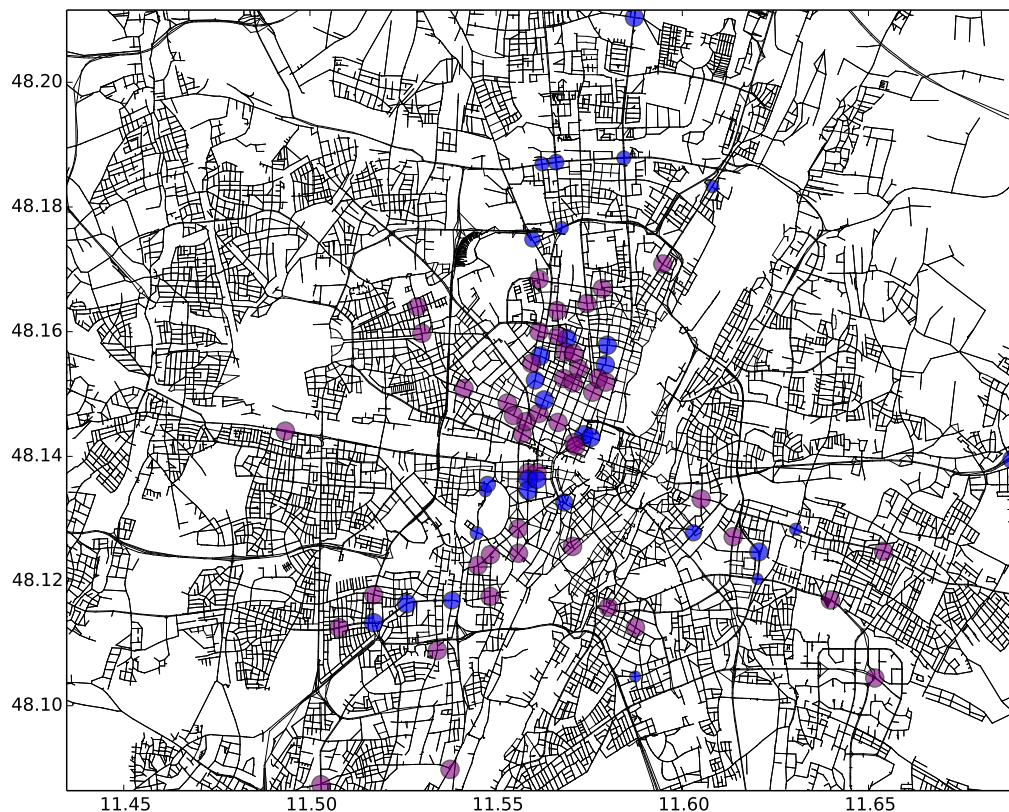


Abbildung 4.9: Festzeitgesteuerte Lichtsignalanlagen (lila) und leicht verkehrsabhängige Lichtsignalanlagen (blau), für die Signalprogrammpläne vom KVR München bereitgestellt wurden.

wurde diese Menge auf 40 Überfahrungen in beiden Geradeausrichtungen geschätzt. Diese gilt es nun, in der Praxis mit realen FCD und Lichtsignalanlagen zu bestätigen. Es wird sich zeigen, dass deutlich komplexere Verfahren als der im theoretischen Teil vorgestellte Ansatz nötig sind, um diese Werte zu erreichen. Es werden im Folgenden unterschiedliche, im Rahmen dieser Arbeit untersuchte und evaluierte Ansätze zur Rekonstruktion der Umlaufzeit vorgestellt und gegenübergestellt. Ziel ist es, mehr Informationsgehalt aus den vorhandenen Datensätzen abzuleiten, um die Qualität der rekonstruierten Daten einerseits zu verbessern, aber andererseits auch die Anzahl von benötigten Überfahrten zu reduzieren.

4.3.3.3 Extraktion von Merkmalen für deren Nutzung zur Signalzustandschätzung

Um Verfahren zur Umlaufzeitrekonstruktion zu generieren, müssen Merkmale gefunden werden, anhand derer möglichst aussagekräftige Gesetzmäßigkeiten abgeleitet werden können. Eine gängige Herangehensweise ist die Extraktion

dieser mithilfe von Verfahren der Mustererkennung. Hierzu werden im ersten Schritt Hypothesen für geeignete statistische Muster anhand geeigneter Darstellungsformen gewählt. Im nächsten Schritt werden sodann die Beobachtungen anhand von mathematischen Gesetzmäßigkeiten nachgewiesen. Im folgenden Abschnitt wird zunächst auf beobachtete Verhaltensmuster eingegangen. In den Abschnitten I bis VI erfolgt die mathematische Ausformulierung und Gestaltung eines automatisierten Verfahrens zur Mustererkennung.


Ausgegangen wird im Folgenden von einer Menge von Teilpfaden für eine bestimmte Fahrtrichtung F_{ea}^z . Jedes Element $f_i^z \in F_{ea}^z$ repräsentiert eine Folge von Positions- und Zeitstempel $f_i^z = (p_o, p_1, \dots, p_n)$, wie sie in Abschnitt 4.3.3.1 beschrieben sind. Die FCD liegen also für die betrachteten Fahrverkehre, klassifiziert nach eingehender und ausgehender Kante und beschnitten um den 75 Meter Radius um die entsprechende Haltelinie, vor. Im Weiteren wird nun jeder Teilpfad f_i^z vom zweidimensionalen in den eindimensionalen Raum übertragen, indem die Euklidische Distanz $d_i := \|(\lambda_i, \delta_i) - (\lambda_{i+1}, \delta_{i+1})\|_2$ zwischen den einzelnen aufeinanderfolgenden Punkten (p_i, p_{i+1}) errechnet wird. Diese wird in einem Distanzpunkt $\text{dst}_i = (d_i, t_i)$ bestehend aus zurückgelegter Distanz d_i und Zeitpunkt t_i hinterlegt. Die Teilpfade bestehen nun aus einer Folge von Distanzpunkten $f_i^d = (\text{dst}_o, \text{dst}_1, \dots, \text{dst}_n)$ ausgehend vom Schnittpunkt zum gezogenen Radius, welche mit absoluten Zeitstempeln t_i versehen sind.

Im nächsten Schritt wird für jede aufgezeichnete Fahrt der umlaufzeitrelative Zeitstempel eines jeden Distanzpunktes dst_i errechnet: Die vorliegenden FCD sind mit Zeitstempel ab dem 1.1.1970, 00:00 Uhr versehen. Unter Berücksichtigung der lokalen Zeit kann nun die relative Zeit τ_i einer angenommenen Umlaufzeit T errechnet werden:


$$\tau_i = \text{mod}(t_i, T) \quad (4.15)$$

Abbildung 4.10 illustriert die verarbeiteten Daten einer Kreuzung (Pestalozzi/Blumenstr) anhand eines Weg-Zeit (WZ)-Diagramms. Hier flossen 243 FCD aus einem Zeitraum von etwa 9 Monaten ein, wobei jeweils die Zeiträume montags zwischen 13:00 Uhr und 19:00 Uhr berücksichtigt wurden. Diese Abbildung ist wie folgt zu interpretieren:

Jede der abgebildeten Kurvenverläufe stellt eine Kreuzungsüberquerung durch ein Fahrzeug dar. Muss ein Fahrzeug an einem Signalgeber stehen bleiben, so ist dies anhand eines flacher werdenden Kurvenverlauf, gefolgt von einem Halt (markiert durch ein schwarzes Kreuz) beobachtbar. Die darauffolgende Haltezeit entspricht einem horizontalen Kurvenverlauf auf dem WZ-Diagramm, da hier keine Positionsveränderung stattfindet. Eine nachfolgende Beschleunigung ist am steiler werdenden Kurvenverlauf beobachtbar. Der Zeitpunkt der Anfahrt ist dabei durch ein blaues Kreuz dargestellt. Muss ein Fahrzeug nicht an einer Kreuzung halten, so ist dessen Verlauf auf dem WZ-Diagramm eine leicht nach rechts geneigte Gerade. Die Haltelinienüberquerungen dieser Fahrten sind in violett markiert.



(a) Diagramm für eine korrekt geschätzte Umlaufzeit.



(b) Diagramm für eine falsch geschätzte Umlaufzeit.

Abbildung 4.10: Kreuzung Pestalozzi/Blumenstr (München): Ein illustratives Beispiel für die Verkehrsmusteranalyse im Kreuzungsbereich anhand eines Weg-Zeit Diagramms. Die Kurvenverläufe repräsentieren Bewegungsmuster von Fahrern basierend auf 243 aufgenommen Fahrten. Aus jedem FCD wurde eine Teilmenge mit einem 75 Meter Radius um die Haltelinie extrahiert. Abbildung *a* zeigt das Verkehrsflussmuster für eine korrekte Umlaufzeit (90 Sek), Abbildung *b* illustriert eine falsch geschätzte Umlaufzeit (80 Sek). Bei schwarzen Kreuzen handelt es sich um Haltepunkte, blaue Kreuze repräsentieren Beschleunigungspunkte, in violett sind Haltelinienüberquerungen bei Fahrten ohne Stopp dargestellt.

Wird bei der Berechnung des Moduls der Zeitstempel mit der Umlaufzeit nach Formel 4.15 eine korrekte Umlaufzeit angenommen, so kann das Schaltverhalten der betrachteten Lichtsignalanlage anhand des Verkehrsflussmusters offengelegt werden: Im oberen ersten Drittel und im oberen letzten Viertel der Abbildung 4.10a sind viele Verzögerungen bis hin zum Halt zu beobachten. Dies ist auf die Sperrzeit dieser Lichtsignalanlage zu diesen Zeiträumen zurückzuführen. Sie ist zu den Umlaufzeiten $[0, 24]$ und $[70, 90]$ gesperrt. In den Umlaufsekunden 24 bis 35 sind viele Beschleunigungen zu beobachten, was auf den Abbau der Warteschlange an der Kreuzung zurückzuführen ist. In den Sekunden 35 bis 70 ist die Warteschlange in der Regel abgebaut worden, da viele Durchfahrten ohne Stopp zu beobachten sind. Wird dagegen von einer falschen Umlaufzeit wie in Abbildung 4.10b ausgegangen, so ist dieses Muster nicht mehr erkennbar. Hier sind die Zeitpunkte von Beschleunigungen, Stopps, oder Durchfahrten scheinbar wahllos. Diese Beobachtungen lassen sich anhand unterschiedlicher Gesetzmäßigkeiten messen, auf welche im Folgenden eingegangen wird.

Linearität der Beschleunigungspunkte: Die Beschleunigung von Fahrzeugen bei einem Signalwechsel von Rot nach Grün erfolgt nach einem klaren Muster, bei dem die Fahrzeuge in der Warteschlange nacheinander mit einer geringen zeitlichen Verzögerung anfahren. Aus diesem Grund weisen Zeitpunkte von Beschleunigungen an einer Kreuzung einen linearen Zusammenhang zur entsprechenden Position auf. Betrachtet man die Beschleunigungspunkte in Abbildung 4.10a (blaue Punktewolke), so ist ersichtlich, dass sich diese um eine fiktive vertikale, nach links geneigte Gerade häufen. Dieser Sachverhalt ist in der Tat bereits 1994 durch Hoffmann et al. nachgewiesen worden [68], vergleiche hierzu auch Abschnitt 4.2.1.

Varianz der Zeitdifferenzen zwischen Beschleunigungs-, Stopp- und Durchfahrtpunkten (VZ): Ist eine Kreuzung durch eine Lichtsignalanlage koordiniert, so führt die sich wiederholende Phasenfolge zu einer Ordnung von Stopps, Beschleunigungen und Durchfahrten bezüglich der Umlaufzeit der Lichtsignalanlage. Es häufen sich die Haltepunkte (schwarze Punkte in Abbildung 4.10a) zeitlich vor den Beschleunigungen (blaue Punkte), gefolgt von Durchfahrtpunkten (violette Punkte). Es gilt also folgende Ordnung: Stopp < Beschleunigung < Durchfahrt. Ferner fällt bei der Betrachtung auf, dass der Zeitunterschied zwischen den einzelnen Ereignissen relativ stabil ausfällt. Dies kann auf die Koordinierung der Kreuzung durch eine Lichtsignalanlage zurückgeführt werden. Es kann also die Hypothese aufgestellt werden, dass die Varianz der Zeitunterschiede zwischen Stopp-, Beschleunigungs- und Durchfahrtpunkten deutlich geringer für eine koordinierte Kreuzung, bzw. einer korrekt geschätzten Umlaufzeit ausfällt, als bei einer unkoordinierten Kreuzung, respektive falsch geschätzter Umlaufzeit. Bekräftigt werden kann diese Annahme durch die Betrachtung von Abbildung 4.10b, in der die individuellen Punkte zufällig verteilt erscheinen.

Höhere zeitliche Korrelation: Generell existiert ein linearer Zusammen-

hang im Fahrverhalten an Kreuzungen: Fahrer, die eine Kreuzung in derselben Fahrtrichtung überqueren, bewegen sich stets in dieselbe Richtung (korrektes Verhalten vorausgesetzt). Ihre Optionen sind beschränkt auf die Ereignisse „Stopp“, „Beschleunigung“, „Überquerung ohne Halt“; sie weisen also „ähnliche“ Verhaltensmuster auf. Dieser positive, lineare Zusammenhang kann durch den Korrelationskoeffizienten gemessen werden. Dieser Zusammenhang ist noch stärker ausgeprägt, wenn die zeitliche Komponente der Fahrten exakt der Umlaufzeit der Lichtsignalanlage entspricht, da sich viele dieser Ereignisse zeitlich überlappen. Ein passender Ansatz ist es, diesen linearen Zusammenhang für die korrekte Umlaufzeit durch den Korrelationskoeffizienten zu beschreiben.

Leere-Koeffizient: Während die zuvor beschriebenen Gesetzmäßigkeiten statistischer Natur sind, basiert dieser Ansatz auf Bildverarbeitungsmethoden. In den linken und rechten oberen Bereichen sind Freibereiche zu beobachten, die nur entstehen können, wenn Fahrzeuge eines bestimmten Fahrverkehres zu bestimmten Zeitpunkten nicht in die Kreuzung einfahren dürfen. Der flächenmäßige Anteil einer verbundenen Freifläche verglichen zu den nicht freien Bereichen kann ein Indikator für eine korrekt oder falsch geschätzte Umlaufzeit sein. Hierfür wird der Begriff „Leere-Koeffizient“ eingeführt.

4.3.3.4 Verfahren zur Rekonstruktion der korrekten Umlaufzeit

Aus den hier aufgeführten Beobachtungen lassen sich unterschiedliche Verfahren zum Erlernen der korrekten Umlaufzeit entwickeln. Im Folgenden werden die genauen mathematischen Definitionen der zuvor vorgestellten Beobachtungen erläutert und die entsprechenden Verfahren zur Rekonstruktion der korrekten Umlaufzeit definiert.

I. Hypothesentest zur Umlaufzeitrekonstruktion (HY): Während die nachfolgenden Verfahren Herleitungen aus den vorangegangenen Beobachtungen darstellten, ist das Verfahren, mithilfe des Hypothesentests falsche Umlaufzeiten zu verwerfen, bereits in Abschnitt 4.3.1 eingeführt und umfangreich beschrieben worden. Da es jedoch ebenfalls eine Variante zur Rekonstruktion der Umlaufzeit darstellt, wird es an dieser Stelle noch einmal explizit erwähnt.

II. Varianzminimierung von Haltelinienüberquerungen (VH): Der Ansatz der Varianzminimierung von Haltelinienüberquerungen ist motiviert durch die simple Gesetzmäßigkeit, dass Fahrer in eine koordinierte Kreuzung nur bei Grünlicht einfahren. Weil der Signalzustand grün nur in einem festen, vorgeschriebenen Intervall (die „Phase“) vorherrscht, kann gefolgert werden, dass beobachtete Überfahrten ebenfalls in diesem Intervall stattfinden. Rein logisch folgt dieser Ansatz also derselben Intuition wie der zuvor beschriebene Hypothesentest für zwei Geradeausrichtungen. In beiden Ansätzen wird davon ausgegangen, dass sich Haltelinienüberquerungen bei einer korrekt geschätzten Überfahrt in einem definierten Intervall befinden.

Im Unterschied zum vorangegangenen Verfahren wird dieser Sachverhalt durch die Varianz von beobachteten Haltelinienüberquerungen eines bestimmten Fahrverkehres bemessen. Diese muss minimal für eine korrekt geschätzte Umlaufzeit sein. Mit dieser Modifikation erübrigt sich die Beobachtungen zweier Geradeausrichtungen. Es kann statt dessen ein beliebiger Fahrverkehr, idealerweise derjenige mit den meisten Überquerungen, verwendet werden. Ausgangspunkt ist auch hier eine Menge von Teilpfaden $f_i^z \in F_{ca}^z$ mit $f_i^z = (p_o, p_1, \dots, p_n)$, klassifiziert nach Fahrverkehr, wie sie in Abschnitt 4.3.3.1 beschrieben sind. Hieraus werden die einzelnen mit Zeitstempel versehenen Positionspunkte bei Haltelinienüberquerung

$$\text{POS} := \{p_i \mid \forall y \in \mathbb{R} : \|(\lambda_i, \delta_i) - (\lambda_h, \delta_h)\|_2 \leq y \wedge d_i > d_{i-1}\} \quad (4.16)$$


aus jedem Teilpfad extrahiert. In Worten handelt es sich dabei um den jeweiligen Punkt mit minimaler euklidischer Distanz zur Haltelinie ohne Nullgeschwindigkeit. Nun kann die relative Zeit τ_k jeder einzelnen Haltelinienüberquerung p_k einer angenommenen Umlaufzeit T errechnet werden:

$$\tau_k = \text{mod}(t_{p_k}, T). \quad (4.17)$$

Dabei ist p_k ein Element aus der Menge POS, $p_k \in \text{POS}$. Die Umlaufzeit kann zwischen 30 Sekunden und 120 Sekunden betragen. Es folgt also: $T \in \{x \in \mathbb{N} \mid 0 \leq x \leq 120\}$. Für alle Umlaufzeitkandidaten werden die Varianzen der Haltelinienüberquerungen τ_k bestimmt:

$$\text{Var}(\tau_k) = E((\tau_k - \mu)^2) \quad (4.18)$$

Eine Veranschaulichung der so berechneten Varianzen ist in Abbildung 4.11 dargestellt. Anhand des Histogrammes ist die zeitliche Verteilung von Überfahrten relativ zu einer angenommenen Umlaufzeit abgebildet. Die erwartete quadratische Abweichung der Zufallsvariablen von ihrem Erwartungswert („Varianz“) ist eine valide Methode, die Breite der Verteilung quantitativ zu bemessen. Durch die Wahl des Umlaufzeitkandidaten mit der minimalen Varianz kann die wahrscheinlichste Umlaufzeit bestimmt werden. Da die Varianz für kleine Umlaufzeitschätzung per se kleiner ausfällt, muss noch eine Normierung dieser erfolgen: $\Delta \text{Var}_i = \text{Var}_{i+1} - \text{Var}_i$. Das Verfahren der Varianzminimierung von Haltelinienüberquerungen besteht insbesondere durch seine Einfachheit und äußerst geringe Rechenintensität. Jedoch ist dieser Ansatz auch mit einer beträchtlichen Menge von FCD (> 200) nicht in der Lage, eine Genauigkeit im Bereich von 0,999 zu erzielen. Dies ist insbesondere auf die Ungenauigkeit von Haltelinienverortungen zurückzuführen. Wie zuvor beschrieben, liegt die Ungenauigkeit der Verortung bei 1-5 Meter (vgl. Abschnitt 4.3.3.1). Dies kann in mehreren Fällen dazu führen, dass ein Halt vor einer Lichtsignalanlage fälschlicherweise als Haltelinienüberquerung interpretiert wird. In diesem Fall fließen falsche Zeitstempel in die Analyse ein.



(a) Histogramm für eine korrekt geschätzte Umlaufzeit. (b) Histogramm für eine falsch geschätzte Umlaufzeit.

Abbildung 4.11: Kreuzung Kapuzinerstr/Lindwurmstr (München): Histogramm Haltelinienüberquerungen relativ zu einer angenommenen Umlaufzeit auf Basis von 375 aufgenommenen Fahrten. Abbildung *a* zeigt das Verkehrsflussmuster für eine korrekte Umlaufzeit (90 Sek), Abbildung *b* illustriert eine falsch geschätzte Umlaufzeit (80 Sek).

III. Minimierung der Varianz von Beschleunigungspunkten (VB):

Der Ansatz einer Umlaufzeitrekonstruktion anhand der Minimierung der Varianz von Beschleunigungspunkten beschreibt eine Weiterentwicklung des vorangegangenen Ansatzes zur Varianzminimierung von Haltelinienüberquerungen mit dem Ziel, die Anzahl benötigter FCD bei gleichbleibender Genauigkeit zu reduzieren. Geschuldet der Tatsache, dass hohe Ungenauigkeiten hinsichtlich der Verortung von Haltelinien vorliegen, werden nicht mehr Überquerungen dieser zur Rekonstruktion herangezogen, sondern Beschleunigungspunkte mit einem Warteschlangenmodell verknüpft. Das nun vorgestellte Modell greift voraus, denn es handelt sich hierbei um das später eingeführte Modell zur Bestimmung des Freigabestarts. Dieses Modell ist darüber hinaus ebenfalls in der Lage, Umlaufzeitschätzungen abzugeben.

Der Ansatz basiert auf den von Hoffmann et al. vorgestellten Beobachtungen an signalisierten Knotenpunkten [68], beschrieben in Abschnitt 4.2.1. Die Autoren beobachteten, dass der an der Kreuzung an vorderster Stelle wartende Fahrer eine mittlere Startreaktionszeit von 1,31 Sekunden aufweist, während die nachfolgenden Fahrzeuge eine Folgereaktionszeit von 0,78 bis 1,10 Sekunden aufweisen. Aus diesen Eingangswerten wird, ähnlich zu der Herangehensweise von Akçelik und Besley [69], ein Warteschlangenmodell abgeleitet, mit dessen Hilfe es möglich ist, den ungefähren Grünstart zu rekonstruieren. Die von Hoffmann et al. gemessenen Kennzahlen können durch eine lineare Funktion beschrieben werden, die von den nachfolgend beschriebenen Eingangsparametern abhängig ist. Ausgangspunkt ist auch hier wieder eine Menge von Teilpfaden $f_i^z \in F_{ea}^z$ mit $f_i^z = (p_o, p_1, \dots, p_n)$, klassifiziert nach Fahrverkehr, wie

in Abschnitt 4.3.3.1 beschrieben. Aus diesen werden die zurückgelegten Distanzpunkte innerhalb des Radius um die Haltelinie $f_i^d = (dst_o, dst_1, \dots, dst_n)$ bestimmt.

- Der absolute Beschleunigungspunkt $(b_k = (a_k, t_k)) \in BE$ und dessen Abstand zur Haltelinie hd dienen als dynamische Eingangswerte. Der Beschleunigungspunkt b_k besteht dabei aus der Beschleunigung a und Zeitpunkt der Beschleunigung t_b . Beschleunigungspunkte BE werden folgendermaßen berechnet:

$$BE := \{p_i \mid v_{i-1}, v_{i-2}, v_{i-3} < v_{th} \wedge a_i > a_{th}\} \quad (4.19)$$

wobei v_{th} eine Schwellwert-Geschwindigkeit und a_{th} eine Schwellwert-Beschleunigung darstellen und für die Geschwindigkeit v_i gilt:

$$v_i := \frac{d_{i+1} - d_i}{t_{i+1} - t_i}. \quad (4.20)$$

für die Beschleunigung a_i gilt:

$$a_i := \frac{v_{i+1} - v_i}{t_{i+1} - t_i}, \quad (4.21)$$

- Die vergangene Zeit Δt eines Signalwechsel von Rot auf Grün bis zur Beschleunigung eines Fahrzeuges ist abhängig von dessen Position. Die Reaktionszeit des Fahrzeuges an der Haltelinie wird als r_1 , die Folgeaktionszeit nachfolgender Fahrzeuge als r_f bezeichnet.
- Die Anzahl von Fahrzeugen in der Warteschlange wird anhand der mittleren Distanz des betrachteten Fahrzeuges hd_k zum ersten Fahrzeug an der Haltelinie hd_1 und einer durchschnittlichen Fahrzeuglänge l ermittelt.

Das Delta Δt_k zwischen Beschleunigung b_k und Grünstart wird ermittelt mit folgender linearer Funktion:

$$\Delta t_k = r_1 + \frac{hd_k - hd_1}{l} \cdot r_f \quad (4.22)$$

Ein geschätzter Grünstart mithilfe eines Beschleunigungspunktes b_i kann somit wie folgt ausgegeben werden:

$$t_{G_k} = t_{b_k} - \Delta t_k, \quad (4.23)$$

wobei t_{b_k} den Zeitpunkt eines Beschleunigungspunktes b_k darstellt. Die Parameter des Warteschlangenmodells werden entsprechend der Beobachtungen von Hoffmann et al. wie folgt gewählt: $r_1 = 1,3s$, $r_f = 1,0s$, $hd_1 = 1,0m$, $l = 6,5m$. Analog zu Formel 4.17 wird nun die relative Zeit einer Grünstartschätzung t_{G_k} aller beobachteten Fahrten mit Beschleunigungspunkten b_k für

alle möglichen Umlaufzeitschätzungen T errechnet:

$$\tau_{G_k} = \text{mod}(t_{G_k}, T) \quad (4.24)$$

Anschließend wird die Varianz der Grünstartschätzungen für jede Umlaufzeitschätzungen T entsprechend der Formel 4.18 bestimmt. Die Umlaufzeitschätzung, welche die minimale Varianz der Grünstartschätzungen aufweist, wird als der wahrscheinlichste Umlaufzeitkandidat gewählt.

Auch dieses Verfahren weist eine sehr geringe Rechenzeit auf. Im Gegensatz zur Varianzminimierung von Haltelinienüberquerungen ist es in der Lage, eine Genauigkeit im Bereich von 0,999 zu erzielen, jedoch mit einer sehr beträchtlichen Anzahl von aufgezeichneten Beschleunigungsvorgängen (> 200). Vor dem Hintergrund der derzeit spärlichen Verfügbarkeit von FCD und vielmehr der Notwendigkeit, Programmwechsel zu detektieren (vgl. hierzu Abschnitt 4.3.4.2) ist es nötig, die Anzahl erforderlicher FCD weiter zu reduzieren.

IV. Varianz der Zeitdifferenzen (VZ): Der varianzbasierte Ansatz nutzt die Tatsache, dass die Varianz der Zeitunterschiede für Stopps, Beschleunigung und Überquerungen ohne Halt gering für eine korrekte Umlaufzeit ist. Auch hier liegen wieder eine Menge von Teilpfaden $f_i^z \in F_{ea}^z$ mit $f_i^z = (p_o, p_1, \dots, p_n)$, sowie die zurückgelegten Distanzen innerhalb des Radius um die Haltelinie $f_i^d = (\text{dst}_o, \text{dst}_1, \dots, \text{dst}_n)$ vor. Zunächst müssen die einzelnen Fahrten entsprechend Stopps, Beschleunigungen und Überquerungen ohne Halt klassifiziert werden. Hierzu werden Schwellwertklassifizierer herangezogen. Stopps $s_k = (\lambda_k, \delta_k, t_k) \in S$ können entsprechend der Gleichung

$$S := \{p_i \mid v_i < v_{th}\} \quad (4.25)$$

bestimmt werden, wobei die Geschwindigkeit wieder nach Formel 4.20 bestimmt wird und v_{th} eine Maximalgeschwindigkeit darstellt.

Beschleunigungspunkte $b_k \in BE$ werden wieder nach den Formeln 4.19 und 4.21 berechnet.

Eine Fahrt wird als Durchfahrt bezeichnet, wenn kein Stopp auftritt. Als ein Durchfahrtpunkt $q_k = (\lambda_k, \delta_k, t_k) \in Q$ wird dann der nächste Punkt an der Haltelinie gewählt.

$$Q := \{p_i \mid \forall y \in \mathbb{R} : \|\lambda_i, \delta_i - \lambda_h, \delta_h\|_2 \leq y \wedge \forall v_i : v_i > v_{th}\} \quad (4.26)$$

Im nächsten Schritt müssen die errechneten Zeitdifferenzen δt_k zwischen Stopp- und Beschleunigungspunkten, respektive Beschleunigungs- und Durchfahrtpunkten normalisiert werden, um den Effekt der unterschiedlichen Größen geschätzter Umlaufzeiten zu revidieren. Es ergibt sich:

$$\delta t_k^{b_k, s_k} := \frac{(t_{b_k} - t_{s_k}) \cdot 100}{T} \quad (4.27)$$

bzw.

$$\delta t_k^{s_k, q_k} := \frac{(t_{s_k} - t_{q_k}) \cdot 100}{T} \quad (4.28)$$

für jede Umlaufzeitschätzung T . Sodann wird der Mittelwert der Varianzen $Var(X) := E[(X - EX)^2]$ mit $X := \delta t_k^{b_k, s_k}$ respektive $X := \delta t_k^{s_k, q_k}$ errechnet.

V. Korrelationskoeffizient (KK): Ein höherer linearer Zusammenhang von Fahrten bei korrekter Umlaufzeit kann über die zeitliche (Pearson'sche) Korrelation erfasst werden. Als Eingangsparameter steht wieder eine Menge von vorverarbeiteten FCD der Form $f_i^d \in F_{ea}^d$ mit $f_i^d = (dst_o, dst_1, \dots, dst_n)$ zur Verfügung, welche aus den zurückgelegten Distanzen innerhalb des Radius um die Haltelinie bestehen. Die Formel für die Berechnung des Korrelationskoeffizienten ergibt sich zu:

$$CC(X, Y) = \frac{Cov(X, Y)}{\sqrt{Var(X)} \cdot \sqrt{Var(Y)}}, \quad (4.29)$$

wobei X und Y zwei unterschiedliche Zufallsvariablen darstellen. Für diese werden nun die zurückgelegten Distanzen und die dabei benötigten Zeiten $(dst_0^x, dst_1^x, \dots, dst_n^x)$, $(dst_0^y, dst_1^y, \dots, dst_n^y)$ gewählt: $X = dst_i^x$ und $Y = dst_j^y$. Für die Berechnung aller Korrelationskoeffizienten werden alle Kombinationen je zweier aufgezeichneten Fahrten dst_i^x, dst_j^y gewählt. Insgesamt gibt es also n^2 Vergleichsoperationen.

VI. Leere-Koeffizient (LK): Um zusammenhängende, leere Bereiche aus Visualisierungen zu extrahieren, sind einige Vorverarbeitungsschritte nötig. Zunächst wird eine Matrix $M = m_{ij}$ mit der Dimension $m \times n$ erzeugt, wobei gilt: $m = d_{max}$ und $n = T$. Die Diskretisierung ist für Spalten sekunden-genau, für Zeilen metergenau. Als dann wird für jedes Matrixelement die Anzahl der Fahrten, die dieses Feld durchqueren, berechnet. Im nächsten Verarbeitungsschritt wird die Matrix zu einem vollständig vermaschten Netz konvertiert. Jedes Matrixelement wird als Knoten n mit acht Nachbarn betrachtet. Auf diesem Netz kann nun ein Breitensuchalgorithmus angewandt werden, mit dessen Hilfe eine vereinfachte Version des Region Growing Algorithmus [83] zur Suche nach verbundenen Freibereichen durchgeführt wird. Der Algorithmus zur Freibereichssuche wird in Abbildung 1 beschrieben.

Aus der Liste von Freibereichsgraphen, die sich nach der Ausführung von Algorithmus 1 ergeben, wird der flächenmäßig größte extrahiert und das Verhältnis dessen zur Gesamtfläche bestimmt.

$$\Gamma = F/G \quad (4.30)$$

Dabei ist Γ das Verhältnis zwischen größter Freifläche F und Gesamtfläche G . Abbildung 4.12 illustriert die so prozessierten Daten. Das Verhältnis zwischen

Algorithm 1 Freibereichssuche mit Breitensuche

Input: (1) Graph

```
1: procedure EMPTY REGIONS
2:   label all nodes as unvisited
3:   while node unvisited do
4:     choose a random start node from graph
5:     while start node contains a trajectory do
6:       label node as visited
7:       choose new start node
8:     label start node as visited and append it to waiting queue
9:     while waiting queue not empty do
10:      choose first element from waiting queue
11:      if element does not contain a trajectory then
12:        add Element to subgraph
13:        for neighbours of element do
14:          label neighbours as visited
15:          if neighbour does not contain a trajectory then
16:            add neighbour to waiting queue
17:      add subgraph to list empty region graphs
```

Freibereichsgraphen und Gesamtfläche ist jedoch für verschieden Umlaufzeitkandidaten nicht gaussverteilt. Anders formuliert variiert die Gesamtfläche je nach Umlaufzeitkandidat stark - während für einen Umlaufzeitkandidaten von 30 Sekunden eine Fläche von $150m \times 30sek$ aufgespannt wird, ist die Fläche für eine Umlaufzeit von 120 Sekunden vier mal so groß. Aus diesem Grund liegt eine konstante Zunahme des Verhältnisses zwischen Freibereichsfläche und Gesamtfläche vor. Es muss eine Normierung dieser erfolgen.

$$\Delta\Gamma_i = \Gamma_{i+1} - \Gamma_i \quad (4.31)$$

Für die so errechneten Werte wird der Begriff „Leere-Koeffizient“ (LK) eingeführt.

4.3.3.5 Zwischenbewertung

Jedes dieser sechs vorgestellten Verfahren (HY, VH, VB, VZ, KK, LK) ist in der Lage, eine Umlaufzeitschätzung abzugeben. Dazu müssen lediglich die sich aus der erschöpfenden Suche ergebenden Maxima (respektive Minima beim Korrelationskoeffizient) bestimmt und die korrespondierende Umlaufzeit als korrekte Umlaufzeit angenommen werden. Allerdings divergiert die benötigte Anzahl verfügbarer FCD für eine Aussage mit hoher Konfidenz nach Verfahren. In einer Zwischenbewertung wurden Korrekturklassifikationsraten anhand von den 80 Münchner Lichtsignalanlagen, die entsprechend Abschnitt 4.3.3.1 zur Beurteilung herangezogen werden, errechnet. In insgesamt 10.000 Tests wurden




Abbildung 4.12: Kreuzung Kapuzinerstr/Lindwurmstr (München): Heatmap-Visualisierung von verbundenen Freibereichen, die mit dem Freibereichsalgorithmus detektiert wurden. Große verbundene Freibereiche sind in dunkelgrün dargestellt.

zufällig Fahrverkehre und Zeitintervalle ausgewählt.

In Tabelle 4.1 ist eine Zwischenbewertung aufgeführt. In dieser ist ersichtlich,

| KKR | HY | VH | VB | VZ | KK | LK |
|-------------|-----|-----|-----|----|----|-----|
| $\geq 90\%$ | 143 | 70 | 143 | 37 | 27 | 33 |
| $\geq 95\%$ | 240 | 110 | 155 | 44 | 32 | 53 |
| $\geq 99\%$ | - | 244 | 236 | 96 | 57 | 127 |

Tabelle 4.1: Benötigte Anzahl von FCD für Korrektklassifikationsrate je Verfahren.

dass insbesondere die Verfahren VZ, KK, LK eine deutlich niedrigere Anzahl FCD benötigen, um auf dieselbe Korrektklassifikationsrate wie die Verfahren HY, VH, VB zu kommen. Offensichtlich sind die hier verwendeten Merkmale aussagekräftiger als die der anderen Verfahren. Aus diesem Grund werden die Verfahren HY, VH, VB als nicht effizient genug eingestuft und bei den weiteren Ausbaustufen zum Lernen von Umlaufzeiten nicht mehr berücksichtigt.

4.3.3.6 Bayes'sches Training

Das vorgestellte Verfahren ermöglicht es, korrekte Umlaufzeiten anhand von Ausschlägen zu detektieren. Es können die sich aus der erschöpfenden Suche ergebenden Minima (respektive Maxima beim LK-Verfahren) bestimmt und die korrespondierende Umlaufzeit als korrekte Umlaufzeit angenommen werden. Jedoch ist es damit nicht möglich, eine Wahrscheinlichkeitsaussage über die Korrektheit einer getroffenen Aussage zu tätigen. Diese ist jedoch nötig, um Umlaufzeitschätzungen qualitativ bewerten zu können. Ein Formalismus wird

benötigt, die Verlässlichkeit von Umlaufzeitschätzungen zu repräsentieren und aus diesem Wissen Schlüsse zu ziehen. Deshalb wird ein einfaches Bayes'sches Netz auf die vorgestellten Verfahren angewandt.

Bayes'sche Netze sind auch bekannt unter den Begriffen „Belief Networks“, „Probabilistic Networks“, oder „Casual Networks“ und beschreiben einen eben solchen Formalismus, aus unsicherem Wissen Schlüsse zu ziehen. Die Basis hierfür stellt der Satz von Bayes dar, welcher auf kausalen Abhängigkeiten von Wahrscheinlichkeiten beruht. Gegeben sei ein Zufallsexperiment mit einer Menge von Ereignissen $E_i \in \Omega$ mit der Grundgesamtheit $\Omega = \{E_1, \dots, E_n\}$. Ferner gibt es eine Wahrscheinlichkeitsverteilung $P(E)$ mit $P(E) \geq 0$ und $P(\Omega) = \sum_{i=1}^n P(E_i) = 1$. Zwei Ereignisse E_1, E_2 gelten als voneinander stochastisch unabhängig wenn $P(E_1 \cap E_2) = P(E_1) \cdot P(E_2)$, das heißt die individuellen Ereignisse beeinflussen sich nicht gegenseitig. Für bedingte Wahrscheinlichkeiten gilt hingegen: $P(E_1 \cap E_2 \cap \dots \cap E_n) = P(E_1) \cdot P(E_2|E_1) \cdot P(E_3|E_1 \cap E_2) \cdot \dots \cdot P(E_n|E_1 \cap \dots \cap E_{n-1})$. Hierbei bezeichnet $P(E_i|E_j)$ die Wahrscheinlichkeit, dass Ereignis E_i eintritt unter der Bedingung dass Ereignis E_j eingetreten ist. Der Satz von Bayes hingegen formuliert den Zusammenhang von Ereignissen zueinander. Er ist definiert wie folgt:

$$P(E_i|E_j) = \frac{P(E_j|E_i) \cdot P(E_i)}{P(E_j|E_i) \cdot P(E_i) + P(E_j|\bar{E}_i) \cdot P(\bar{E}_i)} = \frac{P(E_j|E_i) \cdot P(E_i)}{P(E_j)}$$

Die Bayes-Formel wird häufig zur Bemessung des Grades des Dafürhaltens (oder Grad der Gewissheit, Grad der Überzeugtheit) eines bestimmten Ereignisses verwendet. So könnten etwa Kontextinformationen aus dem Fahrzeugumfeld auf die Eintretenswahrscheinlichkeiten bestimmter Ereignisse (etwa lokale Gefahrenwarnung) hinweisen. Erreicht wird dies durch Lernen anhand von Beobachtung in einem Training-Schritt. Oftmals ist es möglich, bestimmte Ereignisse und deren Ursachen zu beobachten. Als Beispiel wäre die Beobachtung erhöhter Unfallzahlen und einer häufigen Ursache „Fahrbahnässe“ zu nennen. Der Satz von Bayes erlaubt es nun, auf Basis einer Menge von Beobachtungen eine Unfallwahrscheinlichkeit bei Fahrbahnässe auszugeben. Hierzu wird die Unfallwahrscheinlichkeit in bedingte Abhängigkeit zur Fahrbahnässe gesetzt.

Ein Bayes'sches Netz kann dargestellt werden als ein gerichteter, azyklischer Graph bestehend aus Hypothesen und deren Abhängigkeiten. Dabei repräsentieren die Knoten des Graphen eine Eintretenswahrscheinlichkeit, während die Kanten die Abhängigkeiten zwischen den Hypothesen formulieren. Mit Bayes'schen Netzen können so komplexere Sachverhalte mit mehreren Beobachtungen formuliert werden.

Bestimmung von Bayes-Wahrscheinlichkeiten anhand von Beobachtungen: Um die vorgestellten Verfahren (VZ, KK, LK) zur Erkennung der korrekten Umlaufzeit zu befähigen, aus den abgeleiteten Resultaten belastbare

Schlüsse zu ziehen, muss zunächst aus einer Menge von Beobachtungen gelernt werden (Training). Dabei liegen zweierlei Informationsquellen vor:

- Vom KVR München wurden Schaltzeitinformationen von Lichtsignalanlagen zur Verfügung gestellt. Für diese wurde eine Menge von 80 Referenz-Lichtsignalanlagen bestimmt, anhand derer die entwickelten Verfahren evaluiert werden sollen, vgl. Abschnitt 4.3.3.1.
- Diese Lichtsignalanlagen werden von ungefähr 60.000 der 400.000 aufgezeichneten Fahrten (FCD) gequert.

v_m sei ein Wert v , welcher mit einer Methode m (VZ, KK, LK) aus einer Menge FCD für einen bestimmten Fahrverkehr einer Lichtsignalanlage errechnet wurde. Ein möglicher Wert wäre ein Korrelationskoeffizient von 0.642 aus dem Verfahren KK. Gesucht ist nun eine Aussagewahrscheinlichkeit, dass es sich bei der zugehörigen Umlaufzeit T um die korrekte Umlaufzeit handelt. Es muss also die Wahrscheinlichkeit $P(T_{\text{korrekt}}|v_m)$ bestimmt werden. Diese kann anhand der Bayes'schen Regel ermittelt werden:

$$P(T_{\text{korrekt}}|v_m) = \frac{P(v_m|T_{\text{korrekt}}) \cdot P(T_{\text{korrekt}})}{P(v_m)} \quad (4.32)$$



Für die Anzahl an Umlaufzeitkandidaten gilt nach wie vor: $T \in \{x \in \mathbb{N} | 0 \leq x \leq 120\}$. Dabei ergeben sich bei einem Test mit einem Satz an Teilpfaden f_{ea}^z für einen bestimmten Fahrverkehr 89 Werte falscher Umlaufzeitkandidaten und ein Wert für die korrekte Umlaufzeit. Es können beliebig viele Tests an unterschiedlichen Fahrverkehren und verschiedenen Lichtsignalanlagen durchgeführt werden, um insbesondere eine hinreichende Menge an Werten für korrekte Umlaufzeitkandidaten zu generieren. Für das Training und das damit einhergehende Testen wird auf eine gängige statistische Methode zurückgegriffen, das dreifachen Kreuzvalidierungsverfahren. Hierbei werden die Daten in drei ungefähr gleich große Partitionen aufgeteilt und anschließend auf zwei Drittel der Daten der Lernprozess durchgeführt und dessen Qualität anhand geeigneter Messzahlen auf dem verbleibenden Drittel getestet. Dieser Schritt wird für alle Kombinationen wiederholt. Um eine Ausgeglichenheit zwischen korrekten und inkorrekten Umlaufzeitkandidaten zu erhalten, werden die Ergebniswerte der inkorrekten mittels uniformen Sampling reduziert.

Die Abbildungen 4.13a, 4.13c und 4.13e zeigen exemplarisch die individuellen Werte aus den vorgestellten Verfahren anhand einer Lichtsignalanlage. Mit erschöpfender Suche wird für jeden Umlaufzeitkandidaten ein Wert v_m (Varianz, Leere-Koeffizient, Korrelationskoeffizient) errechnet. Die Anzahl der in die Berechnung eingeflossenen FCD variiert zwischen 1 und 60. Diese sind durch unterschiedliche Grautöne gekennzeichnet (hellgrau = 0-4 FCD, schwarz = 55-60 FCD). Alle Verläufe weisen, je nach Verfahren, eine negative oder positive Spitze bei der korrekten Umlaufzeit von 90 auf. Aus den Abbildungen 4.13d bis 4.13f ist ersichtlich, dass sich Mittelwert und Median mit zunehmender Anzahl verfügbarer FCD verschieben und die Quartile und folglich auch

die Standardabweichung abnehmen. Bei Betrachtung des Rauschens, insbesondere der dunklen Linien, in Abbildungen 4.13a bis 4.13c, könnte man eine Gauss-Verteilung vermuten. Dies zeigt sich insbesondere an der Schwankung des Wertes in einem begrenzten Intervall. Für den formalen Nachweis wird der Shapiro-Wilk-Test [84] verwendet. Dieser bestätigt, dass die Vermutung zulässig ist, da das festgelegte Signifikanzniveau α von 0.05 in den Tests überschritten wurde ($W = 0.9708, \alpha = 0.078$ (VZ), $W = 0.9714, \alpha = 0.054$ (KK), $W = 0.9423, \alpha = 0.0553$ (LK); $n = 500$). Es ist folglich zulässig, $P(v_m | T_{\text{korrekt}})$ und $P(v_m | T_{\text{inkorrekt}})$ als gaussverteilt anzunehmen.



Auf Basis dieser Annahme kann nun ein Bayes'sches Training durchgeführt werden, indem Mittelwerte und Varianzen der Standard-Normalverteilung aus den Beobachtungen berechnet werden. Allerdings muss hierbei ein weiterer Faktor berücksichtigt werden: Aus den Abbildungen 4.13b bis 4.13f sind Mittelwerte und Standardabweichungen für unterschiedliche Mengen verfügbarer FCD ersichtlich. Die statistischen Verfahren (VZ in Abbildung 4.13b und Korrelationskoeffizient in Abbildung 4.13d) weisen eine deutliche Veränderung des Mittelwertes mit zunehmender Menge verfügbarer FCD auf. Alle drei Verfahren zeigen einen deutlichen Rückgang der Standardabweichung mit zunehmender Menge verfügbarer FCD, was mit dem Gesetz der großen Zahlen begründet werden kann. Der Fehler der Schätzung nimmt also ab. Folglich werden Trainingsläufe mit unterschiedlichen Eingangsmengen von FCD durchgeführt. Hierzu wird die einfließende Menge von FCD schrittweise reduziert, indem ein betrachtetes Zeitintervall verkleinert wird. Dabei wird bewusst keine zufällige Auswahl von FCD getroffen, um Verzerrungen aufgrund zeitlicher Nähe von FCD abbilden zu können. Die so erlernten Werte müssen sodann in einer Trainingstabelle persistiert und für den Lernschritt zur Verfügung gestellt werden. Für das zur Verfügung stehende Testfeld wurden mittels der dreifachen Kreuzvalidierung Trainingstabellen erstellt und anschließend über die Gesamtheit aller Daten gelernt. Die Ergebniswerte sind abgebildet in Tabelle 4.2.

Fusion mittels einfachem Bayes'schem Netz. Jeder der eingeführten Umlaufzeitschätzer (VZ, KK, LK) hat eine individuell ausgeprägte Systematik seiner errechneten Werte. Der VZ-Ansatz weist, wie auch der KK-Ansatz, eine zusätzliche Spitze bei der halben Umlaufzeit auf (vgl. hierzu Abbildungen Abbildung 4.13a). Der Grund hierfür liegt in der Tatsache, dass Beschleunigungsdurchfahrts-, oder Stopp-Punkte auf den halben Restklassenring der eigentlichen Umlaufzeit fallen. Das selbe Phänomen tritt bei der Berechnung des Korrelationskoeffizienten aus den Teilpfaden f_i^d auf (vgl. Abbildung 4.13c). Der LK-Ansatz dagegen weist eine solche Spitze nicht auf. Dagegen sind andere Spitzen zu erkennen, wie etwa bei der Umlaufzeit von 82 in dem in Abbildung 4.13e illustrierten Beispiel. Aus diesem Grund kann die Fusion der einzelnen Ansätze zu einer „Glättung“ aus diesen Werten abgeleiteter Wahrscheinlichkeiten und somit zu einer Reduktion von falsch klassifizierten Umlaufzeitkandidaten führen. Jeder einzelne Ansatz kann mittels Trainingstabelle einen Grad des





(a) Errechnete Werte für das Verfahren „Varianzen der Zeitdifferenzen“ für alle Umlaufzeitkandidaten.

(b) Boxplot für das Verfahren „Varianzen der Zeitdifferenzen“ für unterschiedliche Mengen verfügbarer FCD.



(c) Errechnete Korrelationskoeffizienten der auf den zweidimensionalen Raum reduzierten FCD für alle Umlaufzeitkandidaten.

(d) Boxplot der Korrelationskoeffizienten für unterschiedliche Mengen verfügbarer FCD.



(e) Leere-Koeffizient für alle Umlaufzeitkandidaten.

(f) Boxplot des Leere-Koeffizienten für unterschiedliche Mengen verfügbarer FCD.

Abbildung 4.13: Kreuzung Kapuzinerstr/Lindwurmstr (München): Illustratives Beispiel des Suchprozesses zur Extraktion der korrekten Umlaufzeit mit den drei vorgeschlagenen Modellen. Die Anzahl der in die Berechnung eingeflossenen FCD variiert zwischen 1 und 60. In den linken Grafiken sind diese durch unterschiedliche Grautöne (hellgrau = 0-4 FCD, schwarz = 55-60 FCD) gekennzeichnet. Alle Verläufe weisen eine negative oder positive Spitze bei der korrekten Umlaufzeit von 90 auf. Die Abbildungen auf der rechten Seite stellen das Rauschen um den Mittelwert für verschiedene Mengen von eingeflossenen FCD anhand von Boxplots dar.

| | $v_{VZ} T_{korrekt}$ | | $v_{VZ} T_{falsch}$ | | $v_{KK} T_{korrekt}$ | |
|-------|----------------------|---------|----------------------|----------|----------------------|----------|
| # FCD | mean | var | mean | var | mean | var |
| 1-5 | 146.6 | 21667.1 | 311.0 | 74513.7 | 0.704 | 0.064 |
| 6-10 | 296.8 | 43894.6 | 652.94 | 109700.6 | 0.774 | 0.008 |
| 11-15 | 323.0 | 30593.7 | 863.20 | 98966.0 | 0.776 | 0.006 |
| 16-20 | 349.3 | 34817.8 | 960.45 | 99047.3 | 0.757 | 0.005 |
| 21-25 | 380.1 | 35125.8 | 1029.65 | 85238.5 | 0.762 | 0.004 |
| 26-30 | 391.4 | 38544.5 | 1083.18 | 81127.6 | 0.738 | 0.004 |
| 31-35 | 413.8 | 31787.6 | 1141.86 | 73665.2 | 0.735 | 0.004 |
| 36-40 | 386.7 | 25545.0 | 1142.22 | 67138.4 | 0.738 | 0.004 |
| 41-45 | 429.1 | 29086.0 | 1188.76 | 64380.1 | 0.718 | 0.003 |
| 46-50 | 444.4 | 35936.3 | 1228.08 | 49441.0 | 0.723 | 0.003 |
| 51-55 | 448.5 | 34300.0 | 1225.18 | 55432.6 | 0.723 | 0.003 |
| 56-60 | 471.2 | 34368.3 | 1260.58 | 47209.8 | 0.722 | 0.003 |
| | $v_{KK} T_{falsch}$ | | $v_{LK} T_{korrekt}$ | | $v_{LK} T_{falsch}$ | |
| # FCD | mean | var | mean | var | mean | var |
| 1-5 | 0.611 | 0.080 | 382.0 | 454505.1 | 28.296 | 307175.0 |
| 6-10 | 0.659 | 0.004 | 499.36 | 177458.9 | 8.466 | 93015.1 |
| 11-15 | 0.635 | 0.002 | 547.45 | 148154.6 | 2.619 | 31379.8 |
| 16-20 | 0.621 | 0.001 | 463.24 | 104840.9 | 0.140 | 15518.8 |
| 21-25 | 0.611 | 0.001 | 401.23 | 96394.5 | -0.622 | 8837.51 |
| 26-30 | 0.605 | 0.0009 | 405.06 | 82388.7 | -1.728 | 7393.49 |
| 31-35 | 0.598 | 0.0007 | 349.66 | 66604.1 | -2.020 | 4777.73 |
| 36-40 | 0.592 | 0.0006 | 334.61 | 75681.1 | -2.211 | 4052.39 |
| 41-45 | 0.591 | 0.0005 | 301.85 | 45958.8 | -2.261 | 3062.88 |
| 46-50 | 0.586 | 0.0005 | 280.70 | 29596.3 | -2.031 | 2627.62 |
| 51-55 | 0.584 | 0.0004 | 261.38 | 20893.4 | -2.261 | 2097.55 |
| 56-60 | 0.580 | 0.0004 | 239.61 | 19013.3 | -2.130 | 1669.02 |

Tabelle 4.2: Trainigsergebnisse von ca. 200.000 durchgeführten Trainingsläufen pro Verfahren: Es sind Mittelwerte und Varianzen der Gaussverteilungen für korrekte und falsche Umlaufzeitschätzungen für eine bestimmte Methode m abgebildet. Es wird unterschieden zwischen den drei vorgeschlagenen Methoden (VZ, KK, LK). Das Training der einzelnen Modelle wurde durchgeführt mit unterschiedlichen Mengen von FCD.

Dafürhaltens einer jeden individuellen Aussage geben, nämlich $P(T_{korrekt}|v_{VZ})$, $P(T_{korrekt}|v_{KK})$ und $P(T_{korrekt}|v_{LK})$. Diese Aussagen sind voneinander stochastisch unabhängige Wahrscheinlichkeiten und können daher parallel geschaltet werden. Es ergibt sich die gemeinsame bedingte Wahrscheinlichkeit zu:

$$P(T_{korrekt}|v_{VZ}, v_{KK}, v_{LK}) = \prod_i^m \frac{P(v_i|T_{korrekt}) \cdot P(T_{korrekt})}{P(v_i)} \quad (4.33)$$

4.3.4 Vergleichende Bewertung des Verfahrens zum Lernen der Umlaufzeit

Die Evaluation unterteilt sich in zwei Schritte. Zunächst werden die individuellen Verfahren zur Rekonstruktion der Umlaufzeit vergleichend evaluiert, dann wird detaillierter auf die Bayes'sche Fusion eingegangen. Insbesondere wird deren Verhalten der eher theoretischen Potentialabschätzung aus Kapitel 4.3.1 gegenübergestellt.

Anschließend erfolgt eine Analyse des Lernprozesses individueller Signalprogrammanpassungen von Lichtsignalanlagen. Wie in Abschnitt 2.3 erläutert, werden an den meisten Lichtsignalanlagen zeitplanabhängige Signalprogrammanpassungen vorgenommen. Hier können sich alle Steuerungsgrößen einer Lichtsignalanlage, insbesondere Umlaufzeit Phasenabfolge, Freigabe- und Sperrzeiten, ändern. Bei dieser Analyse liegt der Fokus auf der Evaluation der Erkennungsrate (zeitplanabhängige) Signalprogrammänderungen und damit einhergehender Umlaufzeitwechsel.

4.3.4.1 Korrektklassifikationsrate

Für eine Beurteilung der vorgestellten Verfahren ist eine vergleichende Bewertung der einzelnen Korrektklassifikationsraten (KKR) (auch Vertrauenswahrscheinlichkeit genannt) nötig. Im Folgenden wird die Bayes'sche Fusion aus den Verfahren VZ, KK, LK den Verfahren HY, VH und VB anhand ihrer KKR gegenübergestellt. Hierzu werden die individuellen Verfahren anhand der in Abschnitt 4.3.3.1 ausgewählten Referenz-Lichtsignalanlagen evaluiert. Bei der Bayes'schen Fusion werden drei unterschiedliche Trainings- und Testläufe nach der Vorgabe der dreifachen Kreuzvalidierung durchgeführt. Um eine belastbare Menge an Testläufen auf Basis der betrachteten Lichtsignalanlagen mit bekannten Schaltinformationen durchführen zu können, werden Versuche an allen Fahrverkehren einer jeden Kreuzung durchgeführt, womit die Anzahl an Testläufen vervierfacht bis verachtfacht werden kann. Zudem werden Testläufe für alle individuellen Signalprogramme einer Lichtsignalanlage durchgeführt. Um die Testmenge noch weiter zu vergrößern, werden zudem noch mehrere Tests innerhalb eines Signalprogrammes mit schrittweise reduzierter Anzahl von FCD durchgeführt. Insgesamt werden so für jedes Verfahren ca. 4.000 Umlaufzeitschätzungen durchgeführt. Die Ergebnisse sind in Abbildung 4.14 dargestellt. Dabei ist die KKR auf der Ordinate aufgetragen, die jeweilige Anzahl der verfügbaren FCD auf der Abszisse. Die Ergebnisse zeigen deutlich, dass die Bayes'sche Fusion mit Abstand am wenigsten verfügbare FCD benötigt, um eine KKR von 0,999 zu erreichen. Bereits ab 34 verfügbaren FCD ist dieser Zielwert erreicht. Der Hypothesentest (HY) ist dagegen auch mit einer beträchtlichen Menge an FCD nicht in der Lage, diesen Zielwert zu erreichen. Das ist insbesondere auf die begrenzte Phasendauer der Geradeausrichtungen zurückzuführen. So benötigen auch Rechts- und Linksabbieger Räumungszeiten, sowie weitere Anteile der Umlaufzeit, weswegen die tatsächliche Grünzeit




Abbildung 4.14: KKR der Umlaufzeitschätzung für unterschiedliche Verfahren.

der Geradeausrichtung weniger als die Hälfte der Umlaufzeit betragen kann. In diesem Fall ist eine eindeutige Bestimmung der Umlaufzeit nicht mehr möglich, vgl. Abschnitt 4.3.1.4. Die Varianzminimierung von Haltelinienüberquerungen (VH) ist, wie auch die Varianzminimierung von Beschleunigungspunkten (VB), in der Lage, den Zielwert mit ca. 230 aufgezeichneten Fahrten zu erreichen. Verfahren VB wurde ferner in Abhängigkeit von der Anzahl von Beschleunigungspunkten abgebildet. Hier zeigt sich, dass so immerhin mit ca. 40 Beschleunigungspunkten eine KKR von $> 0,95$ erreicht werden kann.

Im Folgenden wird ein genauere Blick auf die Bayes'sche Fusion geworfen. Abbildung 4.15 veranschaulicht die Ergebnisse für geringe Mengen verfügbarer FCD (≤ 50). Neben der KKR der Bayes'schen Fusion aus den Verfahren VZ, KK, LK ist auch die KKR der jeweiligen Teilverfahren dargestellt. Speziell im rechten Drittel ist der Effekt der Fusion erkennbar. Während jede der drei Methoden für sich immer noch falsche Klassifikationen aufweist, kann das durch eine Fusion dieser behoben werden. Dabei wirkt die Berechnung der gemeinsamen bedingten Wahrscheinlichkeit der Bayes'schen Fusion nach Formel 4.33 wie eine „Glättung“. Ausreißer für einzelne Ergebnisswerte können so herausgefiltert werden, die KKR steigt. Beim Vergleich dieser Ergebniswerte mit den Zielwerten aus Abschnitt 4.3.1 zeigt sich, dass diese deutlich übererfüllt werden konnten: In der theoretischen Betrachtung wurden ca. 40 Haltelinienüberquerungen in jede der beiden Geradeausrichtungen benötigt, um eine korrekte Umlaufzeit mit einer KKR von mehr als 0,999 bestimmen zu können. Das Verfahren zur Bayes'schen Fusion kann bereits mit 40 Überquerungen eines einzelnen Fahrverkehrs die Umlaufzeit mit einer KKR von mehr als 0,999 erfassen. Erklärtes Ziel dieses Abschnittes war es, den Informationsverlust aufgrund von Rauschen zu kompensieren und die Anzahl benötigter FCD weiter

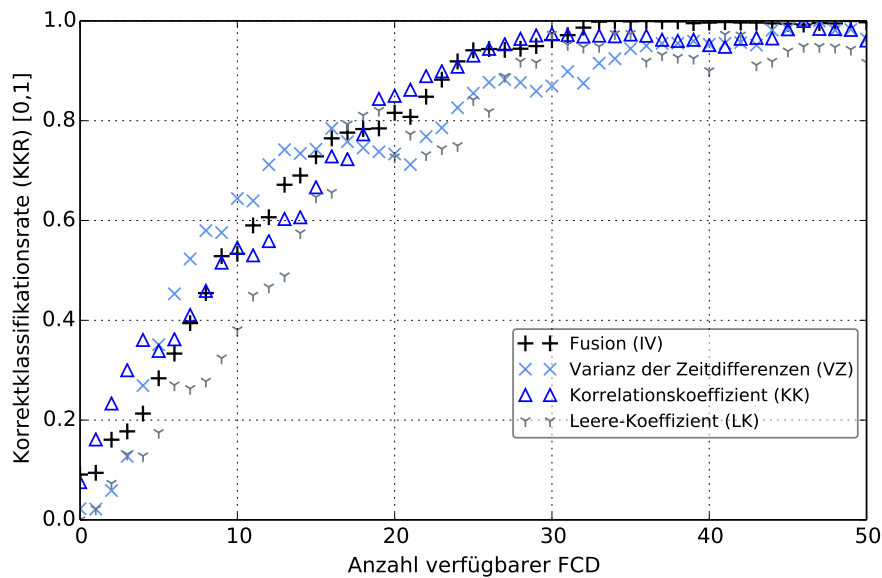


Abbildung 4.15: KKR der Verfahren VZ, KK, LK und der Bayes'schen Fusion derer.

zu reduzieren, indem ein komplexeres Modell zur Umlaufzeitrekonstruktion gewählt wird. Mithilfe der Wahl aussagekräftiger Merkmale und der Fusion dieser anhand eines einfachen Bayes'schen Netzes konnte diese Reduzierung erreicht werden.

4.3.4.2 Lernen individueller Signalprogramme von Lichtsignalanlagen

Lichtsignalanlagen, unabhängig davon ob festzeitgesteuert oder verkehrabhängig, wählen ihr Signalprogramm typischerweise anhand bestimmter Uhrzeiten oder bestimmter Kalendertage aus (vgl. Abschnitt 2.3). Hier ändern sich auch oftmals Umlauf- und Freigabe-, sowie Sperrzeiten. Das Verfahren zur Umlaufzeitrekonstruktion muss daher ebenfalls in der Lage sein, Wechsel zu detektieren und Signalprogrammdauern zu lernen. Herausforderung ist hierbei die Tatsache, dass nicht bekannt ist, zu welchen Zeitpunkten Signalprogramme angepasst werden. Folglich müssen die Zeitpunkte wahrscheinlichster Wechsel, respektive definierte Zeitbereiche mit gleichbleibenden Signalprogrammen gefunden werden. Lichtsignalanlagen weisen typischerweise zwischen einem und fünf Signalprogrammen im Tagesverlauf auf. Allerdings kann keine Annahme darüber getätigt werden, wie viele Signalprogrammanpassungen durchgeführt werden und insbesondere wann genau dies geschieht. Auch werden diesbezüglich in der RiLSA oder in anderen Richtlinien zu Steuerungsverfahren keine Vorgaben gemacht. Aus den vom KVR München zur Verfügung gestellten Daten konnten jedoch gängige Richtwerte gefolgert werden. Den vorliegenden Unterlagen zufolge werden je nach Größe und Variation des Verkehrsflusses zwischen einem und sechs Signalprogrammen konzipiert. Fayazi et al. sugge-


rieren ähnliche Kenngrößen für dem US Amerikanischen Markt [51]. In ihren Tests an sechs Kreuzungen in San Francisco weisen die untersuchten Lichtsignalanlagen je vier Signalprogrammanpassungen (6:00, 10:00, 15:00 und 19:00 Uhr) auf. Aus den verkehrstechnischen Unterlagen vom KVR gehen mögliche Signalprogrammanpassungen um 5:00, 6:00, 7:00, 9:00, 10:00, 12:00, 15:00, 16:00, 19:00 und 21:00 Uhr für München hervor. Folgerichtig kann nur abgeleitet werden, dass Wechsel zur vollen Stunde gängig scheinen, definierte Zeitpunkte jedoch nicht in eine Annahme einfließen dürfen. Anders formuliert können Signalprogrammanpassungen prinzipiell zu jeder beliebigen Stunde erfolgen.

Für die Wahl der Zeitbereiche, in denen nach einer Umlaufzeit gesucht werden soll, stellt dies eine große Einschränkung dar; würde etwa nach einer Umlaufzeit im Zeitbereich zwischen 9:00 Uhr und 12:00 Uhr gesucht werden, ein Signalprogrammwechsel jedoch um 10:00 Uhr auftreten, so könnte die korrekte Umlaufzeit nicht bestimmt werden. Man darf also folgern, dass Zeitbereiche der Größe einer Stunde die obere Grenze darstellen. Gerade hier wird noch einmal die Bedeutung eines effizienten Verfahrens zur Umlaufzeitrekonstruktion offensichtlich: Für jeden zu lernenden Zeitbereich muss eine Mindestmenge von aufgezeichneten Fahrten vorliegen. Im vorangegangenen beschriebenen Verfahren konnte diese auf knapp 40 aufgezeichnete Fahrten für eine KKR von 0,999 reduziert werden. Im Folgenden wird die Lernbarkeit von unterschiedlichen Signalprogrammen im Tagesverlauf anhand des Testfeldes von 80 Münchner Lichtsignalanlagen evaluiert. Hierzu werden die Anfragezeiträume für FCD, die eine individuelle Lichtsignalanlage queren, in Ein-Stunden-Intervalle unterteilt. Es wird jeweils der Fahrverkehr mit den meisten aufgezeichneten Fahrten bestimmt und zur Berechnung des wahrscheinlichsten Umlaufzeitkandidaten mittels Bayes'scher Fusion herangezogen.


Monitoring der Qualität: Beim Lernen individueller Programme muss die Qualität einer Aussage berücksichtigt werden. So muss es möglich sein, einem Entscheider eine Wahrscheinlichkeit der Korrektheit einer Aussage mitzuliefern. Ein solcher Entscheider kann zum Beispiel eine Qualitätsanforderung an generierte Informationen sein. Die Bayes'sche Fusion stellt hierzu anhand der errechneten Auftretenswahrscheinlichkeiten ein solches Instrument bereit. Es ist darüber hinaus denkbar, eine Mindestanzahl aufgezeichneter Fahrten zu definieren und ab Erreichen dieses Wertes von einer ausreichenden Qualität auszugehen. Dies ist valide, da sich in der vergleichenden Bewertung aus Abschnitt 4.3.4 eine KKR von 0,999 mit 40 oder mehr aufgezeichneten Fahrten einstellte und sich die KKR zur Anzahl vorliegender FCD relativ konstant verhielt. Aus diesem Grund müssen beide Herangehensweisen für die Auswertung herangezogen werden.

Evaluation der Erkennung Signalprogrammen mit unterschiedlichen Umlaufzeiten: Zur Evaluation der Detektion individueller Signalprogramme werden diese und deren Umlaufzeiten zu den jeweiligen Zeiträumen aus den verkehrstechnischen Unterlagen extrahiert und mit den geschätzten

Umlaufzeitkandidaten verglichen. Auch hier wird wieder die KKR bestimmt. Im Unterschied zur vorangegangenen Auswertung wird untersucht, wie sich die KKR bei Lichtsignalanlagen mit individuellen Signalprogrammanpassungen im Tagesverlauf verhält. Die Lichtsignalanlagen im definierten Testfeld weisen insgesamt ca. 400 Signalprogrammanpassungen auf, etwa 300 davon mit Umlaufzeitwechsel. Die verbleibenden Signalprogrammanpassungen ohne Umlaufzeitwechsel beinhalten Freigabe- und Sperrzeitenanpassungen oder Verschiebungen definierter grüner Wellen. Im Folgenden werden für Ein-Stunden-Intervalle Umlaufzeitschätzungen nach der Bayes'schen Fusion abgegeben und anhand der vorliegenden Signalprogramme auf ihre Korrektheit überprüft. Abbildung 4.16 zeigt die Evaluierungsergebnisse der Signalprogrammerkennung. Dabei wird unterschieden zwischen variierendem Grad des Dafürhaltens (Abbildung 4.16a) und variierender Anzahl erforderlicher FCD (Abbildung 4.16b). Es ist ersichtlich, dass bei einem Grad des Dafürhaltens von mehr als 70% praktisch keine falschen Klassifikationen mehr auftreten. Für diesen Bereich gibt es nur noch Klassifizierungen mit einer $KKR > 95\%$ oder den Zustand „keine Klassifikation“ ($KKR=0$). Bei einem geringeren Grad des Dafürhaltens nimmt auch die KKR ab, jedoch nicht in solchem Maße wie der Grad des Dafürhaltens. So liegt etwa bei einem Grad des Dafürhaltens von 0-15% die KKR in den Mittags- und Nachmittagsstunden immer noch bei etwa 60%. Es ist hervorzuheben, dass die tatsächliche KKR stets über dem a priori angenommenen Grad des Dafürhaltens liegt, weshalb dieser eine zuverlässige untere Schranke für die KKR darstellt. Ferner fällt auf, dass speziell in den Nachmittags- und Abendstunden die höchsten KKR festzustellen sind. Zum einen liegt dies an der Tatsache, dass viele Lichtsignalanlagen nachts bedarfsgesteuert oder inaktiv sind. Zum anderen liegen in den Nacht- und frühen Morgenstunden praktisch keine Fahrten vor. Dieses Bild wird durch Abbildung 4.16b bestätigt. Auch hier zeigt sich eine sehr geringe KKR in den Morgenstunden, meist liegen gar keine Klassifikationen vor. Insbesondere wenn keine Schranke an benötigten FCD gesetzt ist, beobachtet man eine sehr niedrige KKR, welche ab einer erforderlichen Anzahl von FCD von ca. 10-20 in den Zustand „keine Klassifikation“ ($KKR=0$) übergeht. Im Vergleich zu Abbildung 4.16b fällt auf, dass die KKR insbesondere in den Mittagsstunden und für wenig erforderliche FCD höhere Werte aufzuweisen scheint als die KKR in Abbildung 4.16a. Ein solcher Schluss ist jedoch nicht ohne eine Betrachtung der dazugehörigen Anteile tatsächlich ausgegebener Klassifikationen zulässig. Diese finden sich in Abbildung 4.17. An dieser Stelle sei darauf hingewiesen, dass diese Darstellung nur im Kontext der entsprechenden KKR aussagekräftig ist. Der Umstand, nur eine begrenzte Menge an FCD im Rahmen dieser Arbeit zur Verfügung zu haben, führt zu einer generell geringen Quote gelernter Umlaufzeiten (ca. 30% der Zeit für eine KKR von $>95\%$). Schließt man die Nachtstunden (21:00-6:00 Uhr), während derer die meisten Lichtsignalanlagen bedarfsgesteuert oder inaktiv sind, von der Betrachtung aus, so erhöht sich dieser Wert auf 40%. Anders formuliert liegen mit den Testflottendaten in 40% der Tagesstunden ausreichend viele




(a) Errechnete KKR (y-Achse) nach Grad des Dafürhaltens (x-Achse) und Rate im Tagesverlauf (z-Achse).




(b) Errechnete KKR (y-Achse) nach Anzahl erforderlicher FCD (x-Achse) und Rate im Tagesverlauf (z-Achse).

Abbildung 4.16: Auswertung im Testfeld München anhand von 80 Lichtsignalanlagen: Berechnung der durchschnittlichen KKR der individuellen Lichtsignalanlagen mit Signalprogrammanpassungen im Tagesverlauf unter Zuhilfenahme der verfügbaren FCD.



(a) Errechnete Anteile von Klassifizierungen (y-Achse) nach Grad des Dafürhaltens (x-Achse) und Rate im Tagesverlauf (z-Achse).



(b) Errechnete Anteile von Klassifizierungen (y-Achse) nach Anzahl erforderlicher FCD (x-Achse) und Rate im Tagesverlauf (z-Achse).

Abbildung 4.17: Auswertung im Testfeld München anhand 80 Lichtsignalanlagen: Berechnung der durchschnittlichen Anteile von Klassifizierungen der individuellen Lichtsignalanlagen mit Signalprogramm Anpassungen im Tagesverlauf unter Zuhilfenahme der verfügbaren FCD.

| Grad des Dafürhaltens | | | Anzahl FCD | | |
|-----------------------|------------------|-------|------------|------------------|-------|
| Prozent | Klassifikationen | KKR | Anteil | Klassifikationen | KKR |
| alles | 0.964 | 0.846 | alles | 0.964 | 0.846 |
| >0.1 | 0.957 | 0.848 | >5 | 0.946 | 0.862 |
| >0.2 | 0.917 | 0.863 | >10 | 0.893 | 0.877 |
| >0.3 | 0.828 | 0.856 | >15 | 0.793 | 0.890 |
| >0.4 | 0.553 | 0.821 | >20 | 0.717 | 0.897 |
| >0.5 | 0.368 | 0.816 | >25 | 0.637 | 0.905 |
| >0.6 | 0.317 | 0.848 | >30 | 0.535 | 0.903 |
| >0.7 | 0.294 | 0.948 | >35 | 0.446 | 0.929 |
| >0.8 | 0.142 | 1 | >40 | 0.368 | 0.944 |
| >0.9 | 0.098 | 1 | >45 | 0.302 | 0.954 |
| | | | >50 | 0.222 | 0.97 |
| | | | >55 | 0.173 | 0.974 |

Tabelle 4.3: Grad des Dafürhaltens und Anzahl der FCD hinsichtlich KKR.

Fahrten vor, um eine Rekonstruktion mit hoher Qualität zu tätigen. Bei entsprechender Einführung der FCD-Technologie in großem Umfang ist mit einer deutlich höheren Abdeckung zu rechnen. Betrachtet man die Anteile an Klassifizierungen in Abhängigkeit des Grades des Dafürhaltens (Abbildung 4.16a), ist ersichtlich, dass diese konstanter ausfallen als in Abbildung 4.16b. Insgesamt jedoch stellen sich ähnliche Anteile an Klassifizierungen ein: Bei einem Grad des Dafürhaltens von 75%, respektive bei einer Mindestanzahl von FCD in der Höhe von 35 gab es praktisch keine falschen Klassifikationen mehr ($\leq 5\%$). Für diesen Wert liegt der Anteil an Klassifikationen in beiden Fällen bei etwa 30%.

Zur Verdeutlichung des Verhaltens der KKR werden deren Ergebniswerte noch einmal in Tabelle 4.3 dargestellt. Hier ist ersichtlich, dass sich die KKR für beide Herangehensweisen zu der jeweiligen Anzahl an Klassifikationen ähnlich verhalten. Insgesamt lässt sich feststellen, dass individuelle Programme von Lichtsignalanlagen mit bis zu einer KKR von 98% korrekt klassifiziert werden können, falls genügend aufgezeichnete Fahrten vorliegen und Muster erkannt werden können. Liegen keine Qualitätsanforderungen an die KKR vor, so ergibt sich eine KKR von 84% im gesamten Testfeld. An dieser Stelle ist es hilfreich, den Bogen zum einführend dargelegten Nokia-HERE Anwendungsfall zu spannen. Mit der geplanten Erweiterung der bestehenden Kartendienste um Echtzeitinformationen aus den Fahrzeugen als mobile Sensoren ist zu erwarten, dass in naher Zukunft große Mengen an FCD gesammelt und verarbeitet werden können.

4.3.5 FCD-basierte Signalzustandsschätzung im Realumfeld: Lernen von Schaltzeitpunkten

Die Grundlage zur eigentlichen Detektion von Schaltzeitpunkten wurde mit dem zuvor eingeführten Verfahren zur Umlaufzeitschätzung gelegt. Nun gilt es, die Freigabe- und Sperrzeiten individueller Fahrverkehre und Signalprogramme der vorliegenden Lichtsignalanlagen zu lernen. Hierzu muss differenziert werden zwischen der Grünstartschätzung und Rotstartschätzung. Der Grund liegt in den zu detektierenden Charakteristika, die auf einen Grünstart, respektive Rotstart schließen lassen. Während eine Häufung von Beschleunigungen auf einen kurz zurückliegenden Grünstart hinweist, ist der Abbruch von Überfahrungen der Kreuzung ein Indikator für eine eingetretene Rotphase. Im Folgenden wird zunächst ein Verfahren zur Grünstartschätzung eingeführt und evaluiert, gefolgt von einem Verfahren zur Rotstartschätzung.

Grünstartschätzung: Die meisten Schritte des im Rahmen dieser Arbeit entwickelten Verfahrens zur Grünstartschätzung t_G sind bereits im Kontext der Umlaufzeitschätzung vorgestellt worden, da es sich überdies eignet, eine Schätzung der wahrscheinlichsten Umlaufzeit abzugeben. Die technische Detaillierung findet sich daher in Abschnitt 4.3.3.4. Die Formeln 4.19 bis 4.23 beschreiben hierbei die Berechnung des geschätzten Grünstartes t_{G_k} auf Basis eines Beschleunigungspunktes b_k . Aufbauend wird die mittlere Grünstartschätzung t_G wie folgt berechnet:

$$t_G = \sum_{k=0}^n \frac{t_{G_k}}{n} \quad (4.34)$$

Ausgehend von einer zuvor korrekten Umlaufzeitschätzung T kann der umlaufzeitrelative Grünstart τ_G mittels Formel 4.24 bestimmt werden. An dieser Stelle wird noch einmal kurz auf die Funktionsweise des Modells eingegangen. Der Ansatz macht sich die Gesetzmäßigkeiten zunutze, die dem zeitlichen Muster von beschleunigenden Fahrzeugen in einer Warteschlange zugrunde liegen. So konnten Hoffmann et al. zeigen, dass der an der Kreuzung an vorderster Stelle wartende Fahrer mit einer mittleren Startreaktionszeit von 1,31 Sekunden anfährt, die nachfolgenden Fahrzeuge eine Folgereaktionszeit von 0,78 bis 1,10 Sekunden aufweisen [68]. Dieser Sachverhalt wurde in Abschnitt 4.3.3.4 in eine Funktion überführt. Während dieses Verfahren hinsichtlich Effizienz der Umlaufzeitschätzung von anderen Verfahren übertroffen wurde, erreicht es bei der Grünstartschätzung einen vergleichbar niedrigen mittleren Fehler.

Rotstartschätzung: Während der Grünstart eines Fahrverkehrs mittels des Warteschlangenmodells beschleunigender Fahrzeuge geschätzt werden kann, ist eine umgekehrte Herangehensweise für die Rotstartschätzung, nämlich die Betrachtung von Abbremspunkten, nicht zulässig. Dies kann relativ einfach anhand der Tatsache begründet werden, dass Fahrzeuge zeitlich beliebig verteilt (genauer Poisson-verteilt) an eine koordinierte Kreuzung heranhelfen. Auch lässt ein Stopp (im Gegensatz zu einem Start) keinerlei Rück-




Abbildung 4.18: Histogramm zeitlicher Verteilungen von Haltelinienüberquerungen und tatsächliche Grünphase. Über 95% der gemessenen Haltelinienüberquerungen liegen innerhalb der Grünphase.

schlüsse auf den tatsächlichen Signalzustand des zugehörigen Fahrverkehrs zu. Insbesondere ist es möglich, dass eine noch nicht abgebaute Warteschlange ein herannahendes Auto zum Halt zwingt, obwohl schon der Signalzustand Grün vorliegt. Eine valide Annahme ist jedoch, den Beginn des Signalzustandes Rot anhand des Endes der Grünphase zu bestimmen. Offensichtlich dürfen bei Rot keine Fahrzeuge in die Kreuzung einfahren, das Einsetzen von Rot ist also mit dem Abbruch von Haltelinienüberquerungen der entsprechenden Fahrtrichtung gleichzusetzen. Jedoch erfolgt in der Realität kein abrupter Abfall von Haltelinienüberquerungen. So gibt es immer wieder Beobachtungen von Überquerungen, die augenscheinlich bei Rot erfolgen. Die Gründe hierfür sind mannigfaltig: So ist es möglich, dass aufgrund von Ungenauigkeiten in der Haltelinienverortung Zustände fälschlicherweise als Überquerungen klassifiziert wurden, tatsächlich jedoch ein Halt vor der Haltelinie erfolgte. Auch Ungenauigkeiten in den zugrundeliegenden FCD sind möglich. Schlussendlich sind auch Rotlichtverstöße denkbar. Verdeutlicht werden kann dies anhand der Darstellung eines Histogramms zeitlicher Verteilungen von Haltelinienüberquerungen. Aus Abbildungen 4.18 ist ersichtlich, dass ein Abfall von Haltelinienüberquerungen um den Bereich des Signalwechsels auf Rot erfolgte, jedoch auch einige Überquerungen nach dem Ende der Grünphase stattfanden. Aus diesem Grund ist es nicht möglich, lediglich den letzten Überfahrtszeitpunkt für das Ende der Grünphase zu verwenden. Vielmehr erscheint es sinnvoll, zum Mittelwert der Überfahrtszeitpunkte die Standardabweichung, multipliziert mit einem Faktor F , zu addieren und diesen Wert als wahrscheinlichsten Rotstart anzunehmen:

$$t_R = \mu + F \cdot \text{StD} \quad (4.35)$$

Die Ausgangsbasis stellt hier wieder eine Menge von Positionspunkten bei Haltelinienüberquerung nach Formel 4.16 dar. Im vorliegenden Fall liegt die korrekte Umlaufzeit T vor, aus der die relative Zeit der Haltelinienüberquerung

| Anzahl FCD | [0, 50] |]50,100] |]100,150] |]150,200] |]200,250] |]250,300] | ≥ 300 |
|---------------|---------|----------|-----------|-----------|-----------|-----------|------------|
| Faktor | 0.7 | 0.85 | 1 | 1 | 1 | 1.15 | 1.5 |

Tabelle 4.4: Rotstartschätzung: Multiplikationsfaktor für Standardabweichung von Haltelinienüberfahrungen. Unterscheidung nach Anzahl vorliegender FCD.

τ_R nach Formel 4.17 errechnet wird. Je nach Anzahl an gemessenen Überfahrten variieren jedoch Mittelwerte und Standardabweichung. Liegen etwa viele Überquerungen vor, reduziert sich die Standardabweichung teilweise deutlich. Aus diesem Grund wird der optimale Faktor empirisch ermittelt. In einer dreifachen Kreuzvalidierung wird hierzu der Faktor mit dem geringsten mittleren quadratischen Fehler ermittelt. Dabei wird die Menge vorliegender FCD ebenfalls miteinbezogen. Dieser Faktor ist in Tabelle 4.4 dargestellt.


4.3.6 Bewertung des Verfahrens zum Lernen von Schaltzeitpunkten

Im Folgenden werden die Grünstart- und Rotstartschätzungen hinsichtlich der Genauigkeit der Schätzung evaluiert. Es werden wieder Tests an allen Fahrverkehren einer jeden Kreuzung im Testfeld, sowie jedem individuellen Signalprogramm vollzogen. Zur Bewertung der Abweichung zwischen den Grün- respektive Rotstartschätzungen und den tatsächlichen Signalwechseln wird die Wurzel des mittleren quadratischen Fehlers „Root-Mean-Square Error (RMSE)“ (engl. Root Mean Square Error)“ herangezogen. Er ist definiert wie folgt:

$$RMSE(\hat{t}_{G/R}) = \sqrt{MSE(t_{G/R})} = \sqrt{E((\hat{t}_{G/R} - t_{G/R})^2)} \quad (4.36)$$

Dabei stellt $\hat{t}_{G/R}$ die Grün- respektive Rotstartschätzung dar, $t_{G/R}$ den tatsächlichen Grün- respektive Rotstart. Ein zentraler Vorteil der hier vorgestellten Modelle zur Grün- und Rotstartschätzung ist, dass diese, wie auch das Modell zur Umlaufzeitschätzung, die Möglichkeit bieten, eine bestimmte Qualitätsanforderung zu berücksichtigen. In beiden Fällen kann die Standardabweichung um den Erwartungswert (vorliegende Grün- oder Rotstartschätzung) als Qualitätsmaß für die Aussage herangezogen werden. Liegt eine geringe Streuung um den geschätzten Wert vor, so darf der Aussage eine höhere Konfidenz zugesprochen werden, als bei einer hohen Streuung.

Dieser Sachverhalt bestätigt sich anhand der entsprechenden Untersuchung, dargestellt in der Abbildung 4.19a. Anhand des Verlaufs des RMSE für die Grün- und Rotstartschätzung ist ersichtlich, dass dieser deutlich reduziert werden kann, wenn für die maximal zulässige Standardabweichung der Schätzung ein Schwellwert gesetzt wird. So kann der RMSE für die Grün- und Rotstart-



(a) RMSE von Grünstartschätzungen und Anzahl an Schätzungen für variierende maximal zulässige StD. (b) RMSE von Grün- und Rotstartschätzungen für variierende maximal zulässige StD.

Abbildung 4.19: Auswertung im Testfeld München anhand von 80 Lichtsignalanlagen: Evaluation der Grün- und Rotstartschätzung anhand des RMSE. Analyse des RMSE bei variierender maximaler StD, sowie variierender Mindestanzahl an FCD.

schätzung auf unter eine Sekunde reduziert werden. Freilich nimmt demgegenüber die Anzahl an Schätzungen ab. Hier muss ein Entscheider bzw. Qualitätsanforderer individuell entscheiden, auf wie viel Schätzungen er verzichten möchte, um einen gewünschten RMSE zu erreichen.

Abbildung 4.19b stellt den RMSE der Grün- und Rotstartschätzungen in Abhängigkeit zu einer vorliegenden Anzahl von FCD dar. Es ist zu erkennen, dass sich der RMSE der Grünstartschätzung ab etwa 130 Überfahrten auf ± 2 Sekunden einpendelt. Dieser Wert wird ab dieser Anzahl von verfügbaren FCD konstant eingehalten, es erfolgt nur eine marginale Abweichung von diesem. Auch zeigt sich, dass mit einer größeren Anzahl an FCD kein geringerer RMSE erreicht wird. So ist der RMSE mit 300 oder mehr aufgezeichneten FCD nicht geringer als mit 130. Auffallend ist auch, dass bereits ab fünf aufgezeichneten Fahrten ein RMSE von $\pm 3,5$ Sekunden erreichbar ist und dieser bis 50 aufgezeichneten Fahrten konstant auf diesem Niveau bleibt. Erst eine noch größere Menge an Fahrten (50-130 verfügbare FCD) kann zu einer weiteren Verbesserung führen. Die Rotstartschätzung kann hinsichtlich des RMSE nicht an die Grünstartschätzung heranreichen. So zeigt sich anhand Abbildung 4.19b, dass im besten Falle ein RMSE von ± 3 Sekunden erreicht werden kann. Auch legt der Trend der Kurve nahe, dass mit einer noch größeren Menge verfügbarer Fahrten jenseits der 350 auch keine signifikante Verbesserung mehr wahrscheinlich ist. Im unteren Bereich verfügbarer FCD ist, ähnlich zu einer Grünstartschätzung, schon ab einer einstelligen Zahl an FCD ein RMSE beobachtbar, die bis zu etwa 50 Fahrten konstant bleibt. Im Unterschied zu einer Grünstartschätzung von $\pm 3,5$ Sekunden liegt der RMSE jedoch bei etwa ± 6 . Der generell höhere RMSE kann mit der Ermangelung an besserer Gesetzmäßigkeiten als die bloße Haltelinienüberquerung begründet werden.

Während mit dem Warteschlangenmodell eine verlässliche Gesetzmäßigkeit für das Verhalten von Fahrern bei einem Signalwechsel auf Grün gefunden wurde, ist die Rotstartschätzung auf der Basis von Haltelinienüberquerungen größerem systematischem Rauschen unterworfen. Als einflussreichster Faktor wurde hierbei die Genauigkeit der Haltelinienverortung ausgemacht. Es erfolgte eine Referenzverortung einer Haltelinienposition mittels eines Navilock GPS NL-602U USB GPS Empfängers, der laut Herstellerangaben eine Positionsgenauigkeit von 2,5 m CEP (Circular Error Probable) [85] erreicht. In diesem Stichprobentest konnte der RMSE der Rotstartschätzung um ca. 2 Sekunden reduziert werden. Insgesamt sind die hier vorgestellten Verfahren sowohl zur Grünstart- als auch Rotstartschätzung valide und verlässliche Instrumente zur Rekonstruktion des Ampelverhaltens an koordinierten Kreuzungen. Auch im Vergleich mit dem von Fayazi et al. vorgestellten Modell zur Schaltzeitrekonstruktion an ausgewählten Lichtsignalanlagen in San Francisco [51] können diese überzeugen. Die Autoren geben den RMSE des Grünstartes für die fünf untersuchten Lichtsignalanlagen auf ca. 5 Sekunden an. Das vorgestellte Verfahren zur Grünstartschätzung ist in der Lage, ein RMSE von 2 Sekunden zu erreichen. Ohne die Definition eines Schwellwertes für die Varianz ist eine Grünstartschätzung von 4 Sekunden erreichbar. Insbesondere unter Berücksichtigung des umfangreichen Tests mit 80 Lichtsignalanlagen, wovon ein Teil schwach verkehrsabhängig ist, darf hier von aussagekräftigen Werten ausgegangen werden. Hinsichtlich des RMSE von Rotstartschätzungen machen Fayazi et al. keine Angaben.

4.4 Zusammenfassung

In diesem Kapitel wurden Verfahren zur FCD-basierten Schätzung von Signalzuständen von Lichtsignalanlagen vorgestellt. Hierzu wurde im ersten Teil des Kapitels eine umfangreiche Potentialanalyse anhand eines theoretischen Modells zur Schaltzeitschätzung durchgeführt. Erklärtes Ziel war es, die Umsetzbarkeit eines solchen Ansatzes für den praktischen Einsatz nachzuweisen. Hierbei wurde eine Abschätzung der zu sammelnden Anzahl von FCD durchgeführt, die für eine verlässliche Schätzung vonnöten ist. Für die Rekonstruktion der korrekten Umlaufzeit wurde eine formelle Untersuchung des Zusammenhangs von verfügbaren FCD zur Wahrscheinlichkeit der Detektion von falschen Hypothesen möglicher Umlaufzeiten getätigt. Diese dient als untere Schranke für Lernalgorithmen zur Schätzung der korrekten Umlaufzeit im realen Umfeld. Die Untersuchung des Zusammenhangs zwischen der Detektion der korrekten und eindeutigen Umlaufzeit und der verfügbaren FCD wiederum zeichnet ein realistischeres Bild für die Lernalgorithmen. Aufgrund der bewusst gewählten Einfachheit des Modells wurde dieses als Zielwert für spätere Lernalgorithmen im realen Umfeld definiert. Für das zugrunde liegende Modell wurde ein Ausschlussverfahren aufgestellter Hypothesen gewählt. Die Grundannahme war dabei, dass bei einer korrekt gewählten Umlaufzeit zwei Geradeausrichtungen

nie zur gleichen Zeit den Signalzustand grün haben dürfen. Wurde diese Regel verletzt, konnte die angenommene Umlaufzeit verworfen werden. In einer Laborsimulation wurde gezeigt, dass der korrekte Umlaufzeitkandidat stets nach 40 Überfahrten in jede der beiden Geradeausrichtungen gefunden werden kann. Weiterhin wurde eine Verteilungsanalyse der Zeitpunkte von Haltelinienüberquerungen durchgeführt, in der die inverse Gaussverteilung als geeignetes Maß zur Beschreibung der Verteilung bestimmt wurde. Diese diente sodann als Eingangsgröße für eine anschließende Untersuchung zur Genauigkeit von Grün- und Rotstartschätzungen. Mithilfe einer statistischen Auswertung konnte eine obere Schranke, respektive ein Zielwert für die Genauigkeit der Grün- und Rotstartbestimmung definiert werden. Hier wurde die Wahrscheinlichkeit des Auftretens einer Haltelinienüberquerung zu einem bestimmten Zeitpunkt am Anfang, respektive Ende, einer Grünphase bestimmt. Die theoretische Auswertung stellte einen wichtigen Meilenstein für die nähere Untersuchung der Signalzustandschätzung anhand von FCD im realen Umfeld dar. So konnte mithilfe der Abschätzung benötigter FCD das Potential eines Verfahrens zum automatisierten Lernen von Signalzuständen aufgezeigt, aber auch weitere Forschungsarbeiten begründet werden. Darüber hinaus rechtfertigt dies eine Aggregation von FCD aus der Testflotte, welche üblicherweise mit Kosten verbunden ist.

Auf Basis dieser Erkenntnisse konnte im zweiten Teil dieses Kapitels ein komplexer Algorithmus zur Umlaufzeit-, sowie zur Schaltzeitschätzung entworfen werden. Zentrale Herausforderungen waren hierbei sowohl in der Haltelinienverortung, als auch bei den Positionsdaten von FCD die Kompensation von Rauscheinflüssen in der Positionierung, aber auch Fehlverhalten von Fahrern, wie z.B. Rotlichtverstöße. Hierzu wurden zunächst in den vorliegenden FCD geeignete Merkmale zur Mustererkennung des Verhaltens von Fahrzeugen an koordinierten Kreuzungen bestimmt und untersucht. Dabei konnten bereits bekannte Eigenschaften wie das Warteschlangenmodell zur Schätzung von Beschleunigungszeiten nach Akçelik und Besley [69] bestätigt, aber auch neue Merkmale detektiert und weitere Verfahren zur Mustererkennung abgeleitet werden. Aus dem Pool der möglichen Verfahren und deren Merkmalseigenschaften wurden diejenigen mit den stärksten Merkmalsausprägungen ausgewählt. Um ein Maß des Dafürhaltens, d.h. eine Wahrscheinlichkeit für individuelle Aussagen zu generieren, aber auch um die individuellen Ergebnisse zusammenzuführen, wurden für die Verfahren sodann Bayes-Wahrscheinlichkeiten anhand des Testfeldes trainiert und mithilfe der Bayes'schen Fusion miteinander kombiniert. Das so konzipierte Verfahren zur Umlaufzeitschätzung ist in der Lage, den in der Theorie hergeleiteten Zielwert von 40 FCD zu erreichen. Dies war jedoch mit einer deutlichen Komplexitätssteigerung des zugrundeliegenden Modells verbunden, um die Rauscheinflüsse im realen Umfeld zu kompensieren. In der Evaluation zur Erkennung von Signalprogrammen konnte aufgezeigt werden, dass das vorgestellte Verfahren in der Lage ist, eine KKR von mehr als 0,95 zu erreichen. Bei der Grünstartschätzung im realen Umfeld

konnte die statistische Auswertung aus dem ersten Teil dieses Kapitels bei weitem übertroffen werden. So ist bereits mit einer einstelligen Menge von Beschleunigungspunkten ein RMSE von $+/- 3,5$ Sekunden erreichbar. Dieser kann mit ca. 130 aufgezeichneten Fahrten auf $+/- 2$ Sekunden reduziert werden. Die Wahrscheinlichkeit der Beobachtung einer Fahrt innerhalb der ersten fünf Sekunden lag in der statistischen Auswertung mit 50 Überfahrten nur bei durchschnittlich 40%, bei 130 Überfahrten ergab sich eine Wahrscheinlichkeit von etwa 70%. Der Grund für das sehr gute Abschneiden der Grünstartschätzung liegt in der Wahl des Warteschlangenmodells zur Musterrerkennung, das ein sehr geeignetes Modell zur Beschreibung des Verhaltens von Fahrern an signalisierten Kreuzungen zu sein scheint. Die Rotstartschätzung übertrifft die statistische Auswertung des theoretischen Teils leicht. Hier ist mit 130 Haltelinienüberquerungen ein RMSE von $+/- 5,5$ Sekunden, mit 50 Haltelinienüberquerungen ein RMSE von $+/- 4$ Sekunden erreichbar. Die Wahrscheinlichkeiten für eine Beobachtung mit diesen Genauigkeiten lag bei 75% respektive 80%.

5 Ampeladaptives Routing

Die vorangegangenen Kapitel befassten sich mit der crowdsourcingbasierten Schätzung zukünftiger Signalzustände, welche die Grundlage der im Abschnitt 2.1.2 beschriebenen Ampelassistentenfunktionen darstellen. Von diesen dort beschriebenen Funktionen sind beim „Grüne-Welle Routing“, auch „ampeladaptives Routing“ genannt, noch einige Forschungsfragen zu klären, denen sich dieses Kapitel widmet. Großen Forschungsbedarf gibt es insbesondere noch bei der Zukunftsvision der besseren Auslastung des Verkehrsnetzes und der CO₂-Reduktion durch intelligente Routenwahl. Vor dem Hintergrund der zunehmenden Verkehrs- und CO₂-Belastung in urbanen Räumen gewinnt diese Thematik auch gesellschaftlich an Relevanz. So wurde bereits 2010 die Richtlinie 2010/40/EU zur Einführung intelligenter Verkehrssysteme in der EU beschlossen [86]. Sie führte zu einer Reihe nationaler Gesetzesänderungen, wie etwa dem Intelligente Verkehrssysteme Gesetz (IVSG) vom 20. Juni 2013 [87]. Damit einhergehend wurde vom BMVI der Aktionsplan für Intelligente Verkehrssysteme (IVS) vorgestellt, in dem auf die breite Verfügbarkeit von „Echtzeitverkehrsdaten“ für alle Fahrzeuge gedrängt wird. Das ehrgeizige Ziel ist es, bis 2020 nicht nur die vorhandenen Straßen besser auszulasten, sowie die Zahl der Unfälle zu senken. Zugleich sollen auch der Kraftstoffverbrauch und die CO₂-Emissionen sinken.

Das nachfolgend vorgestellte ampeladaptive Routing stellt einen Beitrag zur technischen Umsetzung dieser geforderten Maßnahmen für urbane Ballungsräume dar. Das Ziel des Verfahrens zur ampeladaptiven Routenauswahl ist, die Wartezeiten an Lichtsignalanlagen aufgrund von Rotzeiten zu minimieren und so die Reisezeit zu verkürzen. Damit einhergehend ist durch die Wahl von ampeladaptiven Routen eine Kraftstoffeinsparung zu erwarten, da unnötige Stopps und nachfolgende energieintensive Beschleunigungen an Lichtsignalanlagen vermieden werden können. Aus diesem Grund wurde für die Wahl eines passenden Begriffs der Terminus „ampeladaptives Routing (AA-Routing)“ verwendet: Im Fokus steht die Optimierung einer Route hinsichtlich der Wartezeiten an Ampeln. Indem diese minimiert werden, werden auch Standphasen an roten Ampeln reduziert, jedoch nicht immer vermieden. Der Begriff des „grüne-Welle-Routings“ könnte daher - wenn auch gleichbedeutend - irreführend sein.

Ziel der weiteren Forschung ist es, ein Modell zur Umsetzung einer intelligenten und dynamischen Routingstrategie unter Einbeziehung zukünftiger Schaltzeiten zu konzipieren und hinsichtlich des voraussichtlichen Reisezeitgewinns im realen Umfeld zu bewerten.

Hierbei muss berücksichtigt werden, dass bestehende Kartenmaterialien und deren Graphstrukturen nicht beliebig verändert werden dürfen. Es ist eine Lösung vonnöten, die keine, oder minimale Auswirkungen auf die Berechnungszeit von Routen zur Laufzeit hat, aber auch keine intensiven Anpassungsmaßnahmen in der Graphstruktur- oder beim Routingalgorithmus nach sich zieht. Ferner muss eine Bewertung über tatsächliche Reisezeitersparnisse im realistischen Umfeld durchgeführt werden. Weite Teile des Verfahrens und dessen Ergebnisse wurden durch den Autor in [100] veröffentlicht.

5.1 Vorveröffentlichungen

Die Kerninhalte dieses Kapitels wurden vom Autor bereits in [100] publiziert. Wie in Kapitel 1 ausführlich dargestellt, stammen die in den Manuskripten und nachfolgend präsentierten Inhalte bzgl. Idee, Konzepts, Theorie und Evaluation vom Autor der vorliegenden Arbeit. Die in der Veröffentlichung vorgestellte Evaluation wurde im Rahmen dieser Arbeit erweitert. Ebenfalls in dem Manuskript enthalten waren die Abbildungen 5.1b und 5.2.

5.2 Voraussetzungen für das ampeladaptive Routing

Das ampeladaptive Routing unter Einbeziehung von Echtzeitverkehrsinformationen stellt erhöhte Anforderungen an die Verfügbarkeit und Qualität dynamischer Informationen für eine Routenwahl. Diese werden im Folgenden explizit dargelegt.

5.2.1 Verfügbarkeit eines Kommunikationskanals

Während die klassische, statische Routenberechnung mithilfe von Infrastrukturdaten, wie Streckenlängen und Höchstgeschwindigkeit in der heutigen Zeit bereits weit verbreitet ist, ergeben sich durch den immer weiter fortschreitenden Ausbau mobiler Datenkommunikation von 2G (GSM) über 3G (UMTS) hin zu 4G (LTE) viele Möglichkeiten der dynamischen Routenoptimierung. So ist es z.B. möglich, mit dem Floating Car Data-Modell, vgl. Abschnitt 2.4, Bewegungsdaten über diese Telematik-Systeme zu versenden und daraus dynamische Informationen wie Echtzeitverkehrsinformationen zu erzeugen und bereit zu stellen. Als große proprietäre Anbieter dieser Dienste gelten INRIX, HERE oder TomTom, vgl. Abschnitt 2.4.2. Auch können auf diesem Wege Unfallmeldungen, Baustellen oder kurzfristig gesperrte Straßen bei der Routenberechnung angefragt und für die Berechnung der Route zu berücksichtigen werden. Mithilfe der mobilen Datenkommunikation können darüber hinaus auch andere Informationen wie Schaltzeitprognosen zur Routenberechnung hinzugezogen werden.

5.2.2 Verfügbarkeit von Schaltzeitprognosen

Informationen zur Verkehrssituation, Staumeldungen oder Unfallmeldungen sind bereits in relativ hohem Maß verfügbar, vgl. Abschnitt 2.4.2. Live-Information über die aktuellen und zukünftigen Signalzustände von Lichtsignalanlagen dagegen gibt es in umfangreichen Maße noch nicht. Um einen ampeladaptiven Routingdienst anbieten zu können, sind diese jedoch unabdingbar. Im Rahmen dieser Arbeit können jedoch die generierten Schaltzeitprognosen der Kapitel 3 und 4 zur Modellierung eines dynamischen Routingverfahrens herangezogen werden. Dabei soll nicht nur ein neues Routingverfahren unter Berücksichtigung von Schaltzeitprognosen herangezogen werden, sondern auch evaluiert werden, unter welchen Rahmenbedingungen ein solcher Dienst gewinnbringend angeboten werden kann. Wie sich in den Kapiteln 3 und 4 zeigte, ist es nicht möglich, mit bestehenden Verfahren eine flächendeckende Prognose von zukünftigen Schaltzeiten zu generieren. Folglich ist ebenfalls zu untersuchen, ob trotz dieser Teilverfügbarkeit von Prognosen das Angebot eines ampeladaptiven Routingverfahrens sinnvoll erscheint.

5.2.3 Verfügbarkeit von Verkehrsinformationen

Neben Schaltzeitinformationen sind auch Verkehrsinformationen für ein ampeladaptives Routing vonnöten. Um einen maximalen Reisezeitgewinn zu erhalten, müssen aktuelle und voraussichtliche Reisezeiten auf den einzelnen Kanten zum Ziel verfügbar sein. Ohne diese ist die Wahrscheinlichkeit, aus der vorberechneten ampeladaptiven Route aufgrund von Verzögerungen herauszufallen, sehr hoch. Neuere Generationen von Navigationsgeräten beziehen bereits Echtzeitverkehrsinformationen in die Routingwahl ein, vgl. Abschnitt 2.4.2. Diese Informationen können folglich für die ampeladaptive Routingwahl ebenfalls als gegeben vorausgesetzt werden. Für die Implementierung des ampeladaptiven Routings in München stehen stochastische Reisezeitschätzungen und Echtzeitverkehrsinformationen im gewählten Referenzzeitraum zur Verfügung. Es handelt sich dabei um Navigationsdaten der BMW-Group. Dennoch können Echtzeitverkehrsinformationen von der tatsächlichen Verkehrslage abweichen. Aus diesem Grund wird evaluiert, welche Qualitätsanforderung an die Genauigkeit der Echtzeitverkehrsinformationen gestellt werden muss.


Die Bemessung der Abweichung von Echtzeitverkehrsinformationen zur tatsächlichen Verkehrssituation gilt jedoch als schwierig und ist derzeit Gegenstand von Forschungsarbeiten. Als Kernproblem gilt hier die Tatsache, dass kein Ground-Truth verfügbar ist. Mithilfe der FCD-Technologie können ferner nur Stichprobenuntersuchungen durchgeführt werden, die ebenfalls kein ganzheitliches Bild liefern können. Auch stellen andauernde, mikroskopische Geschwindigkeitsveränderungen auf einzelnen Kanten weitere Herausforderungen bei der Bewertung. Es gibt jedoch schon erste Verfahren zur Bewertung der Reisezeitschätzung in der Literatur. So stellen Palmer et al. ein Verfahren vor, mit dessen Hilfe es möglich ist, vorliegende Echtzeitverkehrsinformation auf

Autobahnen mithilfe von FCD zu bewerten und die Abweichung in der Reisezeit zu quantifizieren [88]. Sie sind in der Lage, mit Durchdringungsraten von FCD $>1\%$ einen Fehler in der Reisezeit von weniger als 5% nachzuweisen. Noch komplexer gestaltet sich die Bewertung der urbanen Verkehrsprognosequalität, die derzeit intensiv beforscht wird, u.a. auch in einem Forschungsprojekt des Fachbereichs Verkehrsinformationsmanagement, Routenoptimierung der BMW Group.


5.2.4 Eindeutigkeit der Zuordnung von Kanten des Routinggraphen zur Signalgruppe einer Lichtsignalanlage

Verkehrsnetze weisen insbesondere in urbanen Ballungsräumen Besonderheiten im zugrundeliegenden Routinggraphen auf, die das ampeladaptive Routing erschweren. Ein Straßennetz spannt einen gerichteten Graphen auf. Jede Kante ist mit Attributen wie die *Länge* der Kante, *Lane Category* (Anzahl der Fahrspuren), *Speed Category* (Geschwindigkeitskategorie auf der Kante) oder *Intersection Category* (Zusatzinformationen über Kreuzungen, etwa Restriktionen) versehen.

Graphen zur Straßennavigation enthalten dagegen üblicherweise keine Informationen zu Lichtsignalanlagen. Für ein ampeladaptives Routing sind diese aber unverzichtbar. So müssen die Geopositionen aller Haltelinien, einzelne Signalgruppen einer Lichtsignalanlage und zugehörige Schaltzeitprognosen bekannt sein und im Graphen adäquat repräsentiert werden. In der vorgestellten Lösung werden dazu Haltelinienpositionen als Attribute auf den Kanten gespeichert, die auf signalisierte Kreuzungen zuführen. Die zentrale Herausforderung ist hier jedoch die Bestimmung der korrekten Signalgruppe. Haben Abbieger eine andere Freigabezeit als Geradeausfahrer, existieren mehrere Signalgruppen. So können etwa Linksabbieger andere Schaltzeiten haben als Geradeausfahrer. Um die korrekte Signalgruppe und damit die entsprechende Prognose zu bestimmen, muss dies somit über die Kombination von eingehender Kante (*Inlink*) und ausgehender Kante (*Outlink*) erfolgen. Abbildung 5.1a zeigt den einfachsten Fall, in dem die korrekte Signalgruppe bereits direkt durch den Inlink und Outlink bestimmt ist. Im Kreuzungsmittelpunkt treffen sich vier Kanten, weshalb dieser durch einen eindeutigen Knoten bestimmt ist. Folglich kann eine Abbiegebeziehung direkt durch die Kombination Inlink und Outlink bestimmt werden. Abbildung 5.1a illustriert dagegen einen Fall, in dem die eindeutige Zuordnung von Abbiegebeziehung zur Signalgruppe erst mit der Kombination von drei Kanten erfolgt. Für die Implementierung des ampeladaptiven Routings wird dies zur Herausforderung: In der Konzeption gängiger Routingalgorithmen wie dem Dijkstra-Algorithmus, respektive A*-Algorithmus, ist eine Persistierung der relevanten Knoten bis zur eindeutigen Bestimmung der entsprechenden Kantenkombination zur Signalgruppe nicht möglich. In Abschnitt 5.4.2 wird dieser Sachverhalt noch einmal ausführlicher



- (a) Einfache Kreuzung: Der Kreuzungsmittelpunkt ist durch einen Knoten definiert. Die Kanten des zugrundeliegenden Routinggraphen sind direkt verbunden. Alle Abbiegebeziehungen (Geradeaus, Linksabbieger, Rechtsabbieger) können durch die direkte Kombination von Inlink und Outlink bestimmt werden.



- (b) Komplexe Kreuzung: Der Kreuzungsmittelpunkt ist durch vier Knoten definiert. Inlink und Outlinks des zugrundeliegenden Routinggraphen nicht sind direkt verbunden. Linksabbieger werden durch einen anderen Signalgeber als Geradeausfahrer koordiniert. Eine eindeutige Zuordnung der Kantenkombination zu dem entsprechenden Signalgeber ist erst mit drei Kanten möglich.

Abbildung 5.1: Repräsentation einer Kreuzung durch Kanten und Knoten: Gegenüberstellung einer einfachen und komplexen Kreuzung.

beschrieben. Es ist an dieser Stelle festzuhalten, dass eine Eindeutigkeit einer Zuordnung von Kantenkombinationen zu einer Signalgruppe zur Laufzeit des Routingalgorithmus in bestehenden Graphen derzeit nicht möglich ist.

5.3 Ansätze zur Routenoptimierung

Im Folgenden werden existierende Ansätze zur Routenoptimierung unter Einbeziehung von Lichtsignalanlagen vorgestellt. Diese teilen sich insbesondere in zwei Bereiche auf: Bei Ansätzen zur mikroskopischen Optimierung der befahrenen Route werden ideale Annäherungsstrategien an signalisierte Kreuzungen auf einer gegebenen Route entworfen. Ansätze des zweiten Teilbereichs behandeln die Wahl der optimalen Route auf makroskopischer Ebene. Hier soll unter Emissions- und Reisezeitgesichtspunkten eine ideale Route gewählt werden. Beide Ansätze lassen sich kombinieren. So könnte auf

makroskopischer Ebene eine Route mit minimalen Wartezeiten an Lichtsignalanlagen gewählt werden und ideale Annäherungsstrategien für diese auf mikroskopischer Ebene bestimmt werden.

5.3.1 Modelle zur optimalen Geschwindigkeitplanung

Die Konzeption idealer Annäherungsstrategien an Lichtsignalanlagen ist in der jüngsten Vergangenheit bereits intensiv erforscht worden.

Bereits 2000 stellen Rakha et al. eine Untersuchung der Auswirkung einer Strecke mit aufeinander abgestimmten Lichtsignalanlagen auf den Kraftstoffverbrauch vor. Sie zeigen, dass Fahrzeuge, die in einer grünen Welle koordiniert sind, bis zu 50% des Kraftstoffverbrauches einsparen können. Asadi und Vahidi veröffentlichen 2009 eine Vorschau des Energie- und Zeiteinsparpotentials bei Einbeziehung zukünftiger Schaltzeiten anhand erster stichprobenartiger Simulationen dieses Szenarios [89]. Auf einer simulierten, geraden Strecke mit sieben Lichtsignalanlagen können sie so eine Reisezeitersparnis von 17,5% und eine Kraftstoffersparnis von 59 % erreichen. In einer Erweiterung stellen sie 2011 ein Verfahren vor, wie eine optimale Annäherungsstrategie durch Eingriffe in die Längsregelung bei ACC (Autonomous Cruise Control) umgesetzt werden könnte. Der benutzte Sensor ist dabei das Kurzstreckenradar [90]. De Nunzio et al. führen eine theoretische Bestimmung der idealen Geschwindigkeitsstrategien über mehrere Kreuzungen hinweg durch [91]. Dazu lösen sie ein Optimierungsproblem unter der Nebenbedingung der Energieverbrauchsminimierung. Durch Xia et al. wurde in einem Testgelände mit einer Lichtsignalanlage und einer Teststrecke von 307 Metern das Kraftstoff-Einsparpotential eines informierten Fahrers getestet [10]. Hier konnte sich der Fahrer an eine vorgeschlagene Geschwindigkeitsempfehlung richten, um einen Halt an der Lichtsignalanlage zu vermeiden. Die Kraftstoffeinsparung lag in den mit einem BMW 535i durchgeführten Testläufen bei 13,6%, die Reisezeitersparnis bei 0,9%. Mahler et al. stellen aufbauend auf bisherigen Annäherungsstrategien ein Modell zur optimalen Annäherung bei unvollständigen bzw. ungenauen Schaltzeitprognosen vor [11]. Hierzu simulieren sie unter Benutzung der Software AOTONOMIE v1210 zur Evaluation des Kraftstoffverbrauches ideale Verzögerungsstrategien zur Vermeidung von Stopps an Lichtsignalanlagen. In ihrer 2014 vorgestellten Veröffentlichung zu demselben Thema erfolgen probabilistische Erweiterungen und weitere Simulationen [12]. Durch Eckhoff et al. wurden die Potentiale und Limitierungen idealer Annäherungsstrategien an Lichtsignalanlagen untersucht [13]. In einer umfangreichen Simulation mit verschiedenen Verkehrsdichten und Ausstattungsraten von Lichtsignalanlagen wurde der jeweilige CO₂-Verbrauch geschätzt. Es zeigte sich, dass zu Schwachlastzeiten ein Einsparpotential von bis zu 11,5% erreicht werden kann, während bei Starkverkehrszeiten und hoher Ausstattungsrate von Annäherungsstrategien sogar ein höherer CO₂-Ausstoß festgestellt wurde. Zurückzuführen ist dies laut Eckhoff et al. auf die Tatsache,

dass bei einer hohen Anzahl von Fahrzeugen mit Annäherungsstrategien und einem gleichzeitig hohem Verkehrsaufkommen Staus verursacht werden.

5.3.2 Modelle zur optimalen Routenwahl

Im Folgenden werden einige Ansätze zur dynamischen Routenwahl vorgestellt, welche, obgleich sie keine direkte Verbindung zum ampeladaptiven Routing haben, als wichtige verwandte Arbeiten erachtet werden sollten. Es gibt bereits einige proprietäre Lösungen (wie INRIX- oder TomTom-Verkehrsinformationen) zur Berechnung von Echtzeitverkehrsinformationen basierend auf FCD (vgl. Abschnitt 2.4). Dennoch gibt es hinsichtlich der Schätzung und Prognose des Verkehrsaufkommens immer noch eine Menge offener Forschungsfragen, insbesondere da viele derzeitige Schätzverfahren noch als zu ungenau gelten [88].

Eine schon etwas ältere Technologie zur Erfassung grober Kennzahlen über Verkehrsfluss und Verkehrsbelastung ist die Erfassung von Fahrzeugen durch Verkehrsmessstellen. Dabei handelt es sich vor allem um eine Maßnahme, die städtische Verkehrszentralen ergreifen, um den Verkehrsfluss zu überwachen und zu steuern. Als Beispiel kann hier die Stadt Zürich genannt werden, die ihre Daten sogar öffentlich zugänglich macht [92]. Aufbauend auf dieser Technologie gibt es Forschungsarbeiten mit dem Ziel, nicht nur Messstellen für die Berechnung des Verkehrsaufkommens zu nutzen, sondern weitere Datenquellen zur besseren Verkehrsschätzung zu nutzen. In einem Ansatz werten die Autoren das akustische Signal von Fahrzeugen am Straßenrand mittels Mikrofonen aus, um anhand der Lautstärke Rückschlüsse auf die Verkehrslage zu tätigen [93]. Ein neuer Ansatz zur zuverlässigen und dynamischen Zielführung wurde von Kaparis et al vorgestellt [94]. In ihrem Modell gehen sie davon aus, dass die Zuverlässigkeit der Reisezeitschätzung für den Fahrer maßgeblich ist. Es wird ein Verfahren vorgestellt, mithilfe dessen es möglich ist, Reisezeitzuverlässigkeiten auf individuellen Wegen zu errechnen. In einer weiteren Veröffentlichung wurde ein instanzbasiertes Lernverfahren zur Schätzung und Prognose von Verkehrskenngrößen unter Nutzung räumlicher und zeitlicher Verkehrsmuster vorgestellt [95]. In ihrem Ansatz gehen sie von der Verfügbarkeit bestimmter Verkehrskenngrößen (etwa via Messstellen oder FCD) aus. Grubwinkler et al. stellen ein Modell zur Vorhersage des Energieverbrauches auf einer gefahrenen Route auf [96]. Sie werten dabei selbst aufgezeichnete FCD im Raum München aus. Die Energieverbrauchswerte auf den einzelnen Kanten könnten für die Wahl einer möglichst sparsamen Route herangezogen werden.

Hinsichtlich des ampeladaptiven Routings scheint nur wenig verwandte Literatur zu existieren. Nach bestem Wissen adressiert lediglich die Veröffentlichung von Apple et al. das ampeladaptive Routing explizit [97]. Das Paper, das von dem Start-Up-Unternehmen „Connected Signals“ in Oregon veröffentlicht wurde [98], stellt eine dynamische Routing-Applikation unter Berücksichtigung derzeitiger Schaltzeitinformationen für Smartphones vor. Hinsichtlich

der Vorhersage zukünftiger Schaltzeiten geben sie an, ein stochastisches Modell zu nutzen. Der genaue Ablauf der Vorhersage zukünftiger Schaltzeiten ist jedoch nicht explizit angegeben. Da laut der Aussage von Apple et al. deren Schaltzeitprognosen auf einem stochastischen Prozess beruhen, geben sie an, dass ihr Algorithmus zur Routenplanung ebenfalls ein stochastischer ist. Hierzu berechnen sie die Wahrscheinlichkeitsverteilung der Ankunft an einem Ort zu einer bestimmten Zeit und leiten daraus eine Wahrscheinlichkeitsverteilung für das Verlassen einer Kreuzung zu einem bestimmten Zeitpunkt. Leider präsentieren die Autoren in ihrer Veröffentlichung nur eine generelle Beschreibung ihres Modells zur Schaltzeitvorhersage und dem Routingmodell, was vermutlich auf deren unternehmerischen Hintergrund zurückzuführen ist. Auch werden keine Aussagen über den Anteil zu prognostizierender Lichtsignalanlagen und der Prognosequalität angegeben. Für die Bewertung der Performance eines ampeladaptiven Routingverfahrens ist das Wissen über die Abdeckung prognostizierbarer Lichtsignalanlagen und die Qualität der Prognose genauso maßgeblich wie aktuelle Verkehrsinformationen. Eine Auswertung hinsichtlich der Qualität von berechneten Routen erfolgte durch Apple et al. jedoch nicht. Auch wird nicht geklärt, in welcher Form die zuvor beschriebenen Unzulänglichkeiten des bestehenden Routinggraphen behoben werden können.

5.4 Konzeption eines ampeladaptiven Routingverfahrens

5.4.1 Implementierung des A*-Algorithmus

Die Basis für den modifizierten ampeladaptiven Routingalgorithmus ist die A*-Suche. Das primäre Ziel des ampeladaptiven Routings ist die Minimierung der Wartezeit an Kreuzungen und damit einhergehend die Reduktion der Gesamtreisezeit. Folglich repräsentiert die A*-Gewichtungsfunktion $g(s, u)$ auf Kante $e = (s, u) \in E$ die durchschnittliche stochastische Reisezeit. Zur Bestimmung der Heuristik $h(u, v)$ wird zunächst die schnellstmögliche Reisezeit der betrachteten Kachel gewählt. Im nächsten Schritt wird eine hypothetische Reisezeit auf der euklidischen Distanz zum Zielknoten z errechnet mittels:

$$h(u, v) = \frac{e(v, z)}{v_{max}}, \quad (5.1)$$

wobei $e(v, z)$ die euklidische Distanz vom Startknoten v zum Zielknoten z repräsentiert und v_{max} die schnellste Route der betrachteten Kachel darstellt. Der A*-Algorithmus hat in kleineren Straßennetzen als zielgerichteter Suchalgorithmus immer noch ein Einsparpotential von Faktor 2 bis 3 bei konservativer Bewertung der Schätzfunktion [54]. Mit der Unterteilung eines Graphen in Kacheln ist es somit möglich, die Schätzfunktion besser zu bewerten, um eine möglichst hohe Performancesteigerung ohne Optimalitätsverlust zu erreichen.

Die Optimalität des A*-Algorithmus ist in der eigenen Referenzimplementierung also gegeben.

5.4.2 Lokale und temporäre Knotenduplikation

Die Identifikation der korrekten Signalgruppe kann bei der Routingwahl nur durch die Kombination des Inlinks und des Outlinks erfolgen. So können etwa Geradeausrichtungen andere Schaltzeiten aufweisen als Abbiegerichtungen. Das wird zur Herausforderung, wenn die in eine Kreuzung einmündenden Straßen durch mehrere Kanten repräsentiert sind. Dies kann auftreten, wenn z.B. eine bauliche Trennung modelliert werden soll. In diesem Fall müsste der ampeladaptive Routingalgorithmus mehrere Knoten voraus expandieren. Erst nach der eindeutigen Bestimmung einer Kantenkombination könnte dann eine Zuordnung zur entsprechenden Signalgruppe erfolgen. Dies kann aber mit dem Dijkstra-Ansatz zur Lösung des kürzeste Wege Problems nicht vereinbart werden: Ein Fallbeispiel anhand der Abbildung 5.2a wird diesen Sachverhalt verdeutlichen: Die Hauptstraße (West nach Ost) ist hier referenziert durch zwei Kanten. Die beiden Signalgeber für Linksabbieger und Geradeausfahrer weisen unterschiedliche Schaltzeiten auf (SG 1 und SG 2).

Das ampeladaptive Routing sucht nun nach dem kürzesten Pfad von Knoten 1 zu Knoten 5. Zunächst werden hierzu die Knoten 4 und 2 expandiert und $(1,2),(2,3)$ als den kürzesten Pfad von 1 zu 3 bestimmt. Wird nun eine hypothetische Wartezeit (Restrotzeit) für SG 1 auf Knoten 5 gelegt, so wäre der Knoten 2 bereits durch den Algorithmus expandiert worden und der nun möglicherweise schnellere, alternative Pfad $(1,4),(4,2),(2,3),(3,5)$ nicht mehr gefunden werden. Die Zuordnung der zusätzlichen Wartezeit auf Knoten 2 oder Kante $(1,2)$ ist ebenfalls nicht möglich, da SG 1 und SG 2 unterschiedliche Schaltzeiten aufweisen.


Zur Lösung dieses Problems wird ein Verfahren zur temporären und lokalen Erweiterung des zugrunde liegenden Graphen eingeführt. Für eine konsistente Lösung des kürzeste Wege Problems mit zusätzlichen Schaltzeitinformationen ist es nötig, diese eindeutig auf die zugehörigen Kantenkombinationen zu projizieren. Dies kann mithilfe eines Algorithmus zur lokalen und temporären Knotenduplikation bestimmter Kanten im Graph erfolgen. Dieser wird beschrieben in Algorithmus 2. Zur Erläuterung folgt eine Beschreibung zum prinzipiellen Verfahren des Algorithmus in Wortform:

1. Bei der Suche der schnellsten Route mit dem modifizierten A*-Algorithmus liegen die zu betrachtenden Knoten in einer geordneten Warteschlange vor. Für jeden aus der Warteschlange entnommenen Knoten wird geprüft, ob es sich um eine koordinierte Kreuzung handelt. Ist dies der Fall, werden alle in Einfahrtrichtung liegenden Signalgruppen angefordert. Für jede Signalgruppe wird der zugehörige Kantenzug, der zur eindeutigen Identifizierung dieser nötig ist, bestimmt.


Algorithm 2 Temporary Node Duplication

Input: (1) an *inlink* to the intersection
(2) A routing graph $g = (v, e)$

- 1: **procedure** NODEDUPLICATION
- 2: *signalgroups* := *g.getSignalGroups(inlink)*
 ▷ get all signalgroups beginning with *inlink*
- 3: **for** $i = 0$ **to** *signalgroups.length* - 1 **do**
 ▷ iterate over signalgroups
- 4: *signalgroup* := *signalgroups[i]*
- 5: *edges* := *signalgroup.getEdgeCombination()*
- 6: **if** *edges.length* == 1 **then**
 ▷ signalgroup identified by one edge
 ▷ no node duplication needed
- 7: **break**
- 8: **else if** *edges.length* > 1 **then**
 ▷ signalgroup identified by more than one edge
- 9: *copiedEdges*;
- 10: **for** $i = 0$ **to** *edges.length* - 1 **do**
 ▷ create copies the connected edges
- 11: *edgeCopy* := *copy(edges[i])*
- 12: *startNode* := *g.getStartNode(edges[i])*
- 13: *startNodeCopy* := *copy(startNode)*
- 14: **if** $i == 0$ **then**
 ▷ first edge of SG's connected edges
- 15: *startNodeCopy.removeOutgoingEdges()*
 ▷ keep the node connected to the graph
- 16: **else**
- 17: *startNodeCopy.removeEdges()*
- 18: *copiedEdges[i - 1].setEndNode(startNodeCopy)*
 ▷ connect startNodeCopy and endNode
- 19: *edgeCopy.setStartNode(startNodeCopy)*
- 20: **if** $i == edges.length - 1$ **then**
 ▷ last edge of SG's connected edges
- 21: *originalEndNode* :=
 g.getEndNode(edges[i])
- 22: *edgeCopy.setEndNode(originalEndNode)*
 ▷ connect the created path to the graph
- 23: *copiedEdges.add(edgeCopy);*



- (a) Die verbleibende Rotzeit der Signalgruppe in Fahrtrichtung ist zu lang. Ein Umweg über Knoten 4 würde eine Zeitersparnis mit sich bringen und einen Stopp vermeiden. Ohne eine temporäre Knotenduplikation wäre das ampeladaptive Routingverfahren nicht in der Lage, diesen Pfad zu finden.



- (b) Temporäre Knotenduplikation und Entfernung der ursprünglichen Knoten aus der Warteschlange. Die Knoten 2 und 3 sind temporär dupliziert. Sie bilden Kantenzüge, die die einzelnen Signalgruppen eindeutig identifizieren.

Abbildung 5.2: Temporäre Knotenduplikation: Motivation und Illustration.

2. Für alle Kantenkombinationen, über die eine Signalgruppe eindeutig identifiziert werden kann, wird eine eindeutige Kopie angelegt.
3. Für jeden Knoten, der innerhalb des relevanten Kantenzuges liegt, wird eine Kopie angelegt. Auch werden alle Knotenattribute kopiert.
4. Alle anderen zu diesen kopierten Knoten verbundenen Kanten, mit Ausnahme derjenigen des kopierten Kantenzuges, werden gelöscht. Die ursprüngliche Kantenkombination wird ebenfalls gelöscht.
5. Die individuellen Kopien des Kantenzuges werden mit dem Ausgangsgraphen verbunden.
6. Die Schaltzeitinformationen werden als zusätzliche Attribute auf den nun eindeutigen Kantenzug einer jeden Signalgruppe gelegt.

Der Prozess der temporären und lokalen Knotenduplikation ist in Abbildung 5.2a und 5.2b dargestellt. Während in Abbildung 5.2a noch der Ursprungsgraph abgebildet ist, zeigt Abbildung 5.2b den Graph nach der Knotenduplikation. Die relevanten Knoten in der Bewegungsrichtung des Fahrzeuges sind

so modifiziert worden, dass zukünftige Schaltzeitinformationen für einen Linksabbiegevorgang und eine Geradeausfahrt separaten, eindeutigen Kantenzügen zugewiesen werden kann. Die temporären Veränderungen können nach der Berechnung der schnellsten ampeladaptiven Route wieder verworfen werden.

5.4.3 Auswirkungen auf die Berechnungszeit

Bezüglich der Berechnungszeit schnellster ampeladaptiver Routen stellt sich die Frage, ob die temporäre Knotenduplikation die Routenberechnung signifikant verlangsamt. Das ist nicht der Fall, wie relativ einfach gezeigt werden kann: Der Prozess der Knotenduplikation ersetzt einen Knoten x in Abhängigkeit der Kantenkombinationen, die die Signalgruppen eindeutig repräsentieren, sowie der Anzahl von Signalgruppen. Für eine Standardkreuzung mit vier eingehenden Straßen ist keine Duplikation nötig. Bei komplexen Kreuzungen (wie etwa in Abbildung 5.2 gezeigt) werden maximal $|sg| \cdot e$ mit $e \in V \wedge e \in \{\text{Kantenkombination der Signalgruppe}\}$ Knoten. Dies liegt daran, dass die mittleren Stützknoten in einem duplizierten Kantenzug stets einen eingehenden Grad von 1 aufweisen. Damit werden für eine komplexe Kreuzung mit insgesamt 12 Kanten maximal 20 neuen Knoten generiert.

5.4.4 Modifikation der A*-Suche nach Knotenduplikation

Im Gegensatz zur klassischen A*-Suche benötigt die ampeladaptive A*-Suche die Startzeit der Reise. Im Rahmen dieser Arbeit wird davon ausgegangen, dass diese nahe beim Zeitpunkt der Routenberechnung liegt. Ausgehend von dieser Zeit errechnet die ampeladaptive A*-Suche Ankunftszeiten an koordinierten Kreuzungen expandierter Knoten unter der Berücksichtigung von stochastischen Reisezeitinformationen. Stellt $g(s, c)$ die Reisezeit eines Startknotens s zu einer Kreuzung c dar, so wird die vorhergesagte Schaltzeit angefragt und auf die Reisezeit aufgeschlagen: $g_{AA}(s, c) = g(s, c) + r$, wobei r eine etwaige Wartezeit darstellt. $h(u, v)$ bleibt unverändert.

5.4.5 Routingstrategie

Bei den ampeladaptiven Routingstrategien wird zwischen zwei Ausprägungen unterschieden. In der ersten Ausprägungsform wird eine ampeladaptive Route einmalig zu Beginn der Fahrt berechnet. Auf dieser wird das Fahrzeug bis zum Ziel geroutet. Dabei ist unerheblich, ob das Fahrzeug aufgrund von unvorhergesehenen Verzögerungen aus der optimalen Route fällt; eine Neuberechnung erfolgt nicht. In der zweiten Ausprägungsform wird eine Bewertung der aktuell befahrenen Route bei jeder Kreuzungsannäherung durchgeführt. Hier wird errechnet, ob sich das Fahrzeug immer noch in dem für die ampeladaptive Route vorgesehenen „Zeit-Tunnel“ befindet. Ist dies nicht der Fall, so muss durch eine erneute Berechnung der ampeladaptiven Route überprüft werden, ob es

sich bei der eingangs errechneten Route immer noch um die ideale Strategie handelt. Gegebenenfalls wird eine neue Route empfohlen.

5.5 Vergleichende Bewertung

Der Mehrwert einer ampeladaptiven Routingstrategie könnte anhand mehrerer Faktoren nachgewiesen werden. Zu diesen gehören unter anderem die Untersuchung des CO₂ Einsparpotentials, Reisezeitgewinn, aber auch objektiv nicht messbarer Einflussgrößen wie der „Stresslevel“ einer Route. Im Rahmen dieser Arbeit wird ausschließlich der Einfluss einer ampeladaptiven Route auf die Reisezeit untersucht. Untersuchungen zur CO₂-Einsparungen stellen für sich allein stehend umfangreiche Forschungsfelder dar und werden daher lediglich im Rahmen verwandter Arbeiten diskutiert. Es zeigte sich hier, dass die Entwicklung CO₂-idealer Heranfahrensstrategien an signalisierte Kreuzungen eine nichttriviale Aufgabe darstellt. Ebenso werden psychologische Faktoren wie Stresslevel, oder Wohlfühllevel einer Route nicht näher betrachtet.

5.5.1 Testfeld

Zur Implementierung und Bewertung des ampeladaptiven Routings wurde ein Testfeld von 100 km² in München definiert. Dazu wurde speziell eine Kachel des Münchner Innenraums betrachtet. Es handelt sich dabei um den Teilbereich im Münchner Ballungsraum mit der höchsten Dichte an Lichtsignalanlagen. Das Testfeld weist 673 Lichtsignalanlagen auf, wobei für 576 dieser Anlagen Schaltzeitschätzungen mit den Verfahren aus den Kapiteln 3 und 4 erzeugt werden können. Dabei werden für 463 verkehrsabhängige Lichtsignalanlagen Prognosen generiert, 113 weitere sind festzeitgesteuert. Abbildung 5.4 zeigt das Testfeld mit dem verwendeten Routinggraphen und den Positionen der Lichtsignalanlagen. Solche, für die Prognosen zur Verfügung stehen, sind durch blau gefärbte Kreise repräsentiert. Die Größe dieser Kreise illustriert die Verfügbarkeit einer Prognose: Je größer der Kreis, desto höher ist der Anteil an Prognosen in einem Umlauf, vgl. hierzu auch Kapitel 3. Der Routinggraph der gewählten Kachel umfasst dabei 24.235 Kanten und 11.867 Knoten. Die Genauigkeit und Verfügbarkeit der Prognosen im Testfeld ist in Abbildung 5.4 dargestellt.

5.5.2 Unbekannte Signalzustände und Signalprognosen

Für die Berechnung einer ampeladaptiven Route ist unvollständiges Wissen über zukünftige Signalzustände eine Herausforderung. Fakt ist aber auch, dass die Generierung von Prognosen an (nahezu) allen Lichtsignalanlagen eines Ballungsraumes derzeit noch Utopie ist, vgl. hierzu auch Abschnitt 2.3.4 und Kapitel 3 dieser Arbeit. Es stellt sich daher die Frage, ob ein ampeladaptives

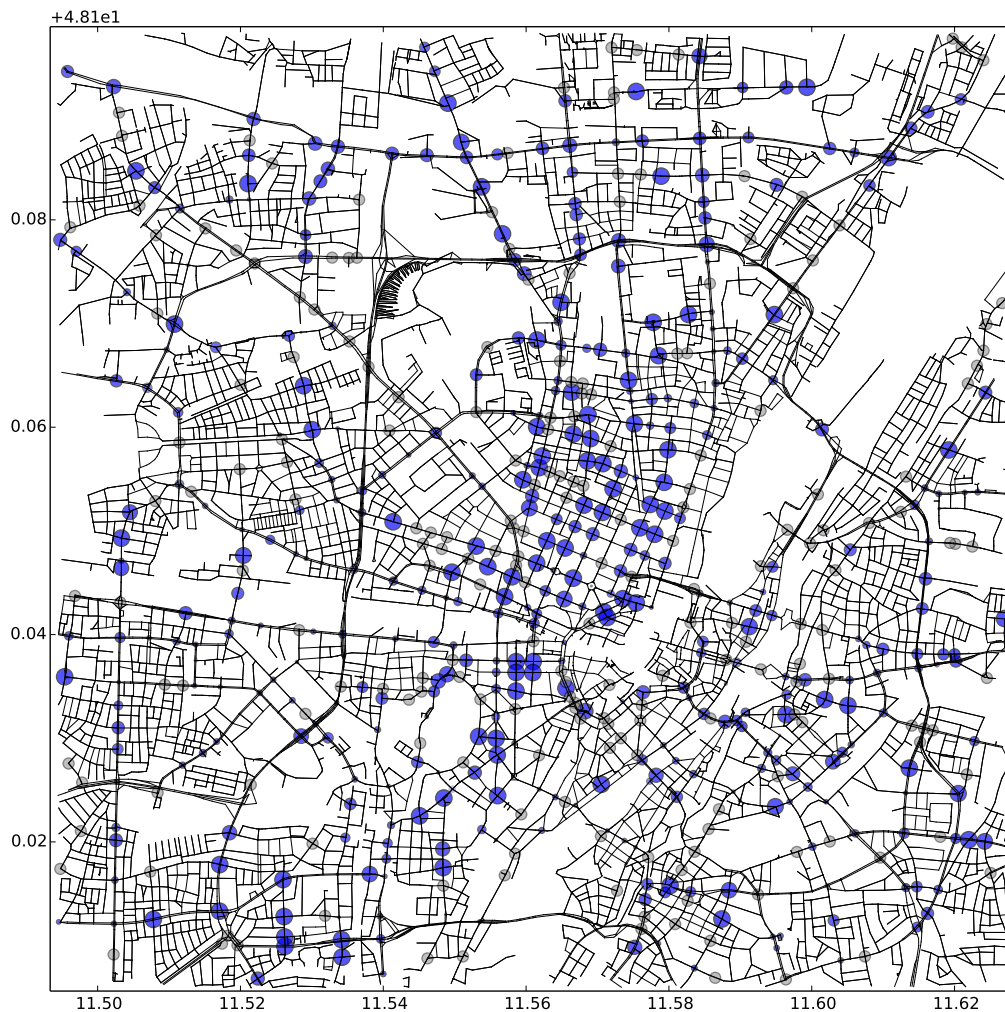


Abbildung 5.3: Testfeld für das ampeladaptive Routing: Routing-Graph und 673 Lichtsignalanlagen, 463 prognostizierbare Lichtsignalanlagen, 100km².

Routing bereits bei einer Teilverfügbarkeit von Prognosen, wie sie in diesem Fall vorliegen, einen Mehrwert liefern kann.

5.5.2.1 Berücksichtigung von unbekanntem Signalzuständen und von Ungenauigkeiten der Signalprognosen

Liegen auf einer möglichen Route mehrere Lichtsignalanlagen, deren zukünftige Signalzustände nicht bekannt sind, könnte eine ampeladaptive Routingstrategie fälschlicherweise diese Route wählen, da sie von keinen Wartezeiten an den entsprechenden Lichtsignalanlagen ausgeht. Tatsächlich jedoch sind diese lediglich unbekannt. Liegen weiterhin auf einer berechneten Route einzelne Lichtsignalanlagen, deren zukünftige Signalzustände nicht bekannt sind, könnte deren Schaltverhalten dazu führen, dass ein Fahrer aus der berechneten op-




Abbildung 5.4: KKR/Verfügbarkeit-Kombination der prognostizierbaren Lichtsignalanlagen im Testfeld (463 prognostizierbare Lichtsignalanlagen).

timalen Route herausfällt. Es muss also eine Strategie gefunden werden, die einerseits Lichtsignalanlagen mit unbekanntem zukünftigen Signalzustand auf einer möglichen Route berücksichtigt. Andererseits muss überprüft werden, dass eine ampeladaptive Route keine zu großen Umwege in Kauf nimmt, da sonst das Herausfallen aus einer solchen Route einen zu großen Zeitverlust darstellen könnte.

Zur Lösung des ersten Problems wird eine durchschnittliche Wartezeit (Strafwert) auf jede überquerte Lichtsignalanlage mit unbekanntem Signalzustand angerechnet. Auf diesem Wege kann verhindert werden, dass eine ampeladaptive Routingstrategie Routen ohne verfügbare Schaltzeitprädiktionen bevorzugt. Die Bestimmung eines idealen Strafwertes muss empirisch erfolgen. Im vorliegenden Fall wurde anhand einer Reihe von Testläufen die durchschnittlich kürzeste Reisezeit einer ampeladaptiven Route für verschiedenen Strafwerte errechnet. Das (lokale) Maximum ergab dabei einen Strafwert von 10 Sekunden. Da dieser Wert jedoch für einzelne Städte, Lichtsignalanlagen und Anteile verfügbarer Prognosen variieren kann, ist eine individuelle Berechnung dieses Wertes und gegebenenfalls ein Fine-Tuning ratsam.

Es können nicht nur Informationen über zukünftige Signalzustände fehlen, auch weisen die Signalprognosen Ungenauigkeiten auf. Hier muss evaluiert werden, ob Schaltzeitprognosen, wie sie im Rahmen dieser Arbeit erstellt werden können, qualitativ ausreichend sind, um mit einer ampeladaptiven Routingstrategie einen Reisezeitgewinn zu erzielen. Dazu werden zwei Testszenarien definiert: Zunächst werden die tatsächlichen Schaltzeiten, die im Testfeld bereit stehen, als ideale Prognosen angenommen. Hierzu wurden die Lichtsignalanlagen des Testfeldes mit den tatsächlichen Schaltzeiten für den Zeit-

raum vom 22. bis 28. September 2014 programmiert. Die Schaltzeitdaten wurden vom KVR München bereitgestellt. Im zweiten Szenario wurden mithilfe der in Kapitel 3 und 4 vorgestellten Verfahren Schaltzeitprognosen für diesen Zeitraum erzeugt. Im Unterschied zum ersten Szenario wurden nun diese zur Berechnung der jeweiligen ampeladaptiven Route herangezogen.

5.5.2.2 Evaluation

Zur Evaluation wurden 22.665 Fahrten mit zufällig gewählten Start- und Endknoten im Testfeld simuliert. Für jede Fahrt wurde eine Standardroutenempfehlung, ampeladaptive Routenempfehlung und eine ampeladaptive Routenempfehlung mit Autokorrektur erstellt. Ungenauigkeiten bei der geschätzten Echtzeitverkehrssituation wurden durch Reisezeitabweichungen mit den Faktoren $[0, 85; 0, 9; 0, 95; 1, 0; 1, 05; 1, 1; 1, 15]$ abgebildet.


Zunächst wird der Einfluss von verfügbaren, aber unvollständigen Schaltzeitprognosen untersucht. Dazu wird der Verkehr als Einflussgröße zunächst ausgeblendet. Bestimmt wird sodann der durchschnittliche Reisezeitgewinn einer ampeladaptiven Routingstrategie zur Standardroutenempfehlung. Der durchschnittliche Reisezeitgewinn G ist definiert wie folgt:

$$G = \frac{R_S - R_{AA}}{R_S}, \quad (5.2)$$

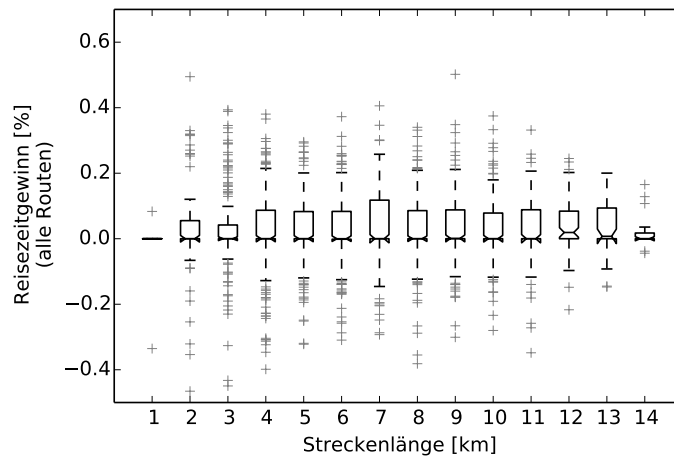
wobei R_S eine Standardroute und R_{AA} die entsprechende ampeladaptive Route darstellt. Die Auswertung des Reisezeitgewinns erfolgt in mehreren Dimensionen: Es wird das Verhalten des Reisezeitgewinns in Abhängigkeit von der Streckenlänge, der Anzahl überquerner Lichtsignalanlagen, Art der Schaltzeitprognose (perfekte Prognose, tatsächliche Prognose), Routingstrategie (ampeladaptive Route, ampeladaptive Route mit Autokorrektur) unterschieden. Abbildungen 5.5 und 5.6 stellen die Ergebnisse dar.

Abbildungen 5.5a und 5.6a zeigen den Reisezeitgewinn nach Streckenlänge und Anzahl überquerner Lichtsignalanlagen bei perfekten Prognosen. Offensichtlich existieren keine Reisezeitverluste, da im gewählten Szenario ideale Bedingungen herrschen. Daher können diese Auswertungen als Benchmark für die Evaluation dienen. Es ist ersichtlich, dass bei einer Streckenlänge von ca. 2 km bis 10 km ein Reisezeitgewinn von über 10% im Mittel erreicht werden kann. Bei längeren Routen nimmt der Reisezeitgewinn wieder ab. Der mittlere Reisezeitgewinn nimmt bei zunehmender Anzahl von überquerten Lichtsignalanlagen jedoch zu und pendelt sich bei ca. 13% ein, wie in Abbildung 5.6a zu sehen ist.


Werden anstelle von perfekten Prognosen tatsächliche Prognosen verwendet, so sind auch Reisezeitverluste möglich. Dennoch überwiegen immer noch die Reisezeitgewinne, denn Mittelwert, Quartil und Median liegen über der x-Achse, vgl. Abbildungen 5.5b, 5.5c, 5.6b und 5.6c. Insbesondere bei Routen mit Lichtsignalüberquerungen im zehnstelligen Bereich oder höher kann ein signifikanter Reisezeitgewinn nachgewiesen werden. Die Ergebnisse sind nicht über-



(a) Perfekte Prognose (tatsächliche Schaltzeiten).




(b) Schaltzeitprognose.




(c) Schaltzeitprognose und Autokorrektur.


Abbildung 5.5: Reisezeitgewinn in Abhängigkeit von der Streckenlänge, Art der Schaltzeitprognose und Routingstrategie.



(a) Perfekte Prognose (tatsächliche Schaltzeiten).



(b) Schaltzeitprognose.



(c) Schaltzeitprognose und Autokorrektur.

Abbildung 5.6: Reisezeitgewinn in Abhängigkeit von der Anzahl überquerrter Lichtsignalanlagen, Art der Schaltzeitprognose und Routingstrategie.


raschend: Eine unerwartete zusätzliche Wartezeit an einer falsch, oder nicht prognostizierten Lichtsignalanlage könnte dazu führen, aus der berechneten ampeladaptiven Route herauszufallen. In diesem Fall hat die ampeladaptive Route dieselben Bedingungen wie die Standardroute. Nähme die ampeladaptive Route große Umwege in Kauf, würde dies zu hohen Reisezeitverlusten führen. Das ist jedoch nicht der Fall, wie aus den Abbildungen 5.5b bis 5.6c) zu sehen ist. Begründet werden kann das mit der maximal zu erwartenden Wartezeit an Lichtsignalanlagen, die einen Wert von 40 Sekunden nur selten überschreitet. Dies wiederum führt dazu, dass bei der ampeladaptiven Route keine zu großen Umwege in Kauf genommen werden. Dasselbe gilt auch an Lichtsignalanlagen ohne verfügbare Prognosen; deren Wartezeiten werden mit einem Strafwert von 10 Sekunden nicht überschätzt und somit werden auch hier keine großen Umwege generiert.

Überdies scheinen Lichtsignalanlagen mit unbekanntem zukünftigen Signalzuständen einen geringeren Einfluss zu haben als erwartet. Ein möglicher Grund ist die Tatsache, dass diese oftmals an Nebenstraßen oder kleineren Straßen positioniert sind. Auch wurde ein für dieses Testfeld optimaler Strafwert bestimmt, der Lichtsignalanlagen mit unbekanntem zukünftigen Signalzuständen offensichtlich sinnvoll berücksichtigt kann.


Den Abbildungen 5.5b und 5.6b liegt die ampeladaptive Routenberechnung ohne Autokorrektur zugrunde, in den Abbildungen 5.5c und 5.6c wurden Neuberechnungen bei Verlassen der idealen Route durchgeführt. Hier sind nur marginale Unterschiede zwischen den Verfahren zu erkennen. Ein Grund hierfür könnte sein, dass bei Herausfallen aus einer ampeladaptiven Route eine komplett anders verlaufende Route offensichtlich nur selten einen Mehrwert hätte.

5.5.3 Ungenauigkeit von Echtzeitverkehrsinformationen.

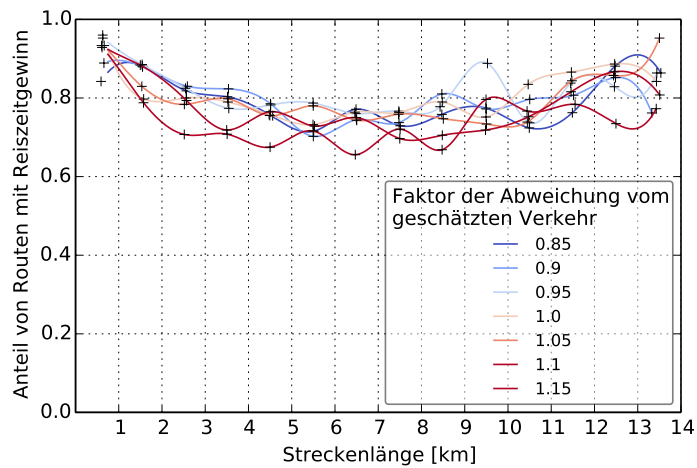
Ziel dieses Abschnittes ist, unter möglichst realistischen Bedingungen eine Abschätzung des wahrscheinlichen Reisezeitgewinns einzelner Fahrzeuge durch den Einsatz einer ampeladaptiven Routingstrategie zu generieren. Die zentrale Herausforderung hierbei ist die Unmöglichkeit, echte und dabei auch signifikante Kennzahlen im realen Umfeld zu generieren. Es müsste eine Reihe von Testfahrten mit Versuchsträgern mit jeweils denselben Start- und Zielkoordinaten durchgeführt werden und dabei jeweils ein Versuchsträger mit und ein Versuchsträger ohne ampeladaptiver Routingempfehlung zum Ziel geroutet werden. Um hier eine aussagekräftige Bewertung zu erhalten, müssten etliche Fahrten zu unterschiedlichen Zeiten und mit unterschiedlichen Distanzen durchgeführt werden, was weder kosten- noch personaltechnisch realisierbar ist. Daher wird hier auf eine simulative Auswertung unter möglichst realistischen Bedingungen zurückgegriffen. Hierzu werden für das in Abschnitt 5.5.1 vorgestellte Testfeld in einer Simulation zufällig je eine ampeladaptive und eine Standardroute mit denselben Start- und Zielwerten berechnet und deren Reisezeiten verglichen.



(a) Perfekte Prognose (tatsächliche Schaltzeiten).




(b) Schaltzeitprognose.




(c) Schaltzeitprognose und Autokorrektur.


Abbildung 5.7: Anteil von Routen mit Reisezeitgewinn in Abhängigkeit von der Streckenlänge, Art der Schaltzeitprognose und Routingstrategie.



(a) Perfekte Prognose (tatsächliche Schaltzeiten).



(b) Schaltzeitprognose.



(c) Schaltzeitprognose und Autokorrektur.

Abbildung 5.8: Anteil von Routen mit Reisezeitgewinn in Abhängigkeit von der Anzahl überquerrer Lichtsignalanlagen, Art der Schaltzeitprognose und Routingstrategie.

Zur Reisezeitberechnung liegen sowohl stochastische Geschwindigkeitsschätzungen auf den individuellen Kanten des Routing-Graphen, als auch Echtzeitverkehrsinfos für den betrachteten Zeitraum vor. Dennoch sind die geschätzten Echtzeitverkehrsinfos mit Ungenauigkeiten behaftet, die zu Abweichungen von der tatsächlichen Reisezeit führen. Aus diesem Grund muss untersucht werden, wie hoch der Anspruch des ampeladaptiven Routings an die Genauigkeit dieser Echtzeitverkehrsinfos ist, um einen Reisezeitgewinn auf der ampeladaptiven Route zu erreichen. Echtzeitverkehrsinfos bilden die Verkehrsbelastung auf Straßen typischerweise durch höhere Reisezeiten ab. Es ist daher ein logischer Ansatz, die Abweichung von der tatsächlichen Verkehrsbelastung anhand abweichender Reisezeiten zu modellieren. Hierzu werden auf den jeweiligen Routen bestimmte Verkehrsbelastungen angenommen, die bezüglich der geschätzten zu einem gewissen Grad differieren und so zu einer prozentualen Abweichung von der geschätzten Reisezeit führen. In insgesamt 68.000 simulierten Fahrten unterschiedlicher Länge und unterschiedlicher angenommener Reisezeitverzögerungen werden so Abweichungen von der tatsächlichen Reisezeit im Bereich $[0,85; 1,15]$ generiert. Ein Wert von 0,85 beispielsweise steht für eine Reisezeit, die lediglich den Faktor 0,85 der mit Echtzeitverkehrsinfos geschätzten Reisezeit benötigt. Die Reisezeit wurde zuvor also überschätzt. Bei einem Faktor von 1,15 war die tatsächliche Reisezeit um ebendiesen Faktor länger als angenommen.


Abbildungen 5.7 und 5.8 zeigen den Anteil von ampeladaptiven Routen mit Reisezeitgewinn (oder gleicher Reisezeit). In dieser Auswertung wurden unterschiedliche Abweichungen von der tatsächlichen zur geschätzten Reisezeit miteinbezogen. Bei einem Faktor kleiner Null war die tatsächliche Reisezeit um ebendiesen Faktor kürzer als geschätzt. Ist der Faktor größer Null, so dauert die Reise auf den jeweiligen Routen entsprechend länger. Abbildungen 5.7a und 5.8a zeigen wiederum den Anteil von Routen mit Reisezeitgewinn nach Streckenlänge und Anzahl überquerrter Lichtsignalanlagen bei perfekten Prognosen. Entspricht die geschätzte Reisezeit der tatsächlichen Reisezeit, so liegt der Anteil der Routen mit Reisezeitgewinn bei 1. Die errechneten ampeladaptiven Routen sind mindestens genau so schnell wie die Standardrouten. Der Anteil von Routen mit Reisezeitgewinn nimmt mit zunehmender Abweichungen von der geschätzten Reisezeit ab. Dabei ist unerheblich, ob es sich um kürzere Reisezeiten oder längere handelt. Wurden Reisezeiten jedoch unterschätzt, die tatsächliche Reisezeit war also länger als geschätzt, so weisen weniger Routen einen Reisezeitgewinn auf als bei einer entsprechenden Überschätzung. So liegt der durchschnittliche Anteil von Routen mit Reisezeitgewinn bei einer Unterschätzung um den Faktor 1,15 bei etwa 70% (rote Linie), während dieser bei einer Unterschätzung um den Faktor 0,85 noch bei 80% liegt.

Bei der Verwendung von Schaltzeitprognosen anstelle von perfekten Prognosen liegen die Anteile von Routen mit Reisezeitgewinn deutlich näher beieinander, vgl. Abbildungen 5.7b und 5.8b. Jedoch ist auch hier für Routen mit unterschätzten Reisezeiten der Anteil schnellerer Routen geringer als bei über-


geschätzten Reisezeiten. Auffällig ist in Abbildung 5.7b, dass mit zunehmender Streckenlänge zunächst der Anteil des Reisezeitgewinns abnimmt, jedoch ab einer Streckenlänge von etwa 7 km wieder zunimmt. Dieses Phänomen tritt jedoch nicht in Abbildung 5.8b auf, die den Anteil schnellerer Routen in Abhängigkeit überquerrter Lichtsignalanlagen darstellt. Zurückzuführen ist dies auf die Funktionsweise des ampeladaptiven Routings: Insbesondere bei längeren Strecken können Routen bevorzugt werden, die weniger Lichtsignalüberquerungen aufweisen, da mit dem ampeladaptiven Routing die Wartezeit an koordinierten Kreuzungen minimiert wird. Ampeladaptives Routing mit Auto-korrektur führt zu einer leichten Erhöhung des Anteils von Reisezeitgewinnen. Dies wird anhand Abbildungen 5.7c und 5.8c deutlich. Insbesondere bei hoher Reisezeitüberschätzung (rote Linie) können neue Routenempfehlungen zu einer geringfügigen Verbesserung führen.

Abschließend wird der mittlere Reisezeitgewinn bei ampeladaptivem Routing im Vergleich zur Standardroutenempfehlung untersucht. Hierzu wird der durchschnittliche Reisezeitgewinn nach Formel 5.2 ermittelt. Es erfolgt wiederum eine Auswertung unter der Berücksichtigung unterschiedlicher Abweichungen zur geschätzten Reisezeit. Die Ergebnisse sind in den Abbildungen 5.9 und 5.10 dargestellt. Abbildungen 5.9a und 5.10a zeigen den Reisezeitgewinn nach Streckenlänge und Anzahl überquerrter Lichtsignalanlagen bei perfekten Prognosen. Bei einer exakten Verkehrsabschätzung liegt der mittlere Reisezeitgewinn bei 11,24%, der mit zunehmender Abweichung von der geschätzten Verkehrssituation abnimmt. Auch hier führt eine Unterschätzung der Reisezeit zu einem größerem Rückgang des Reisezeitgewinns als eine Überschätzung. So liegt der mittlere Reisezeitgewinn bei einer Reisezeitüberschätzung um den Faktor 0,85 noch bei 6,65%, während dieser bei einer Unterschätzung nur noch bei 1,4% im Mittel liegt. Aus Abbildung 5.9a wird eine Abnahme des Reisezeitgewinns mit zunehmender Streckenlänge deutlich. Dem gegenüber nimmt der Reisezeitgewinn mit zunehmender Anzahl überquerrter Lichtsignalanlagen zu, vgl. Abbildung 5.10a.


Werden Schaltzeitprognosen zur Berechnung von ampeladaptiven Routen verwendet, so sinkt der mittlere Reisezeitgewinn bei idealer Verkehrsabschätzung auf 4,95%. Auffallend ist, dass eine Überschätzung der Reisezeit einen deutlich geringeren Effekt auf den Reisezeitgewinn als eine Unterschätzung hat. Dieser bleibt auch bei einer Überschätzung um den Faktor 0,9 bei 3,27%. Bei einer Unterschätzung der Reisezeit kann bei Verwendung von Schaltzeitprognosen ein Reisezeitgewinn mit einer ampeladaptiven Route nicht mehr erreicht werden. So bleibt der mittlere Reisezeitgewinn bis zu einer Unterschätzung von 1,1 bei 0% und sinkt bei 1,15 auf einen Reisezeitverlust von 1,14%. Aus Abbildung 5.9b ist ersichtlich, dass bei überschätzten und leicht unterschätzten Reisezeiten $[0,85;1,05]$ für alle gemessenen Streckenlängen ein Reisezeitgewinn erreicht wird. Bei einer größeren Unterschätzung der Reisezeit kann ein Reisezeitgewinn erst ab 9 km Streckenlänge erreicht werden. Der Reisezeitgewinn steigt dagegen mit zunehmender Anzahl überquerrter Lichtsi-



(a) Perfekte Prognose (tatsächliche Schaltzeiten).




(b) Schaltzeitprognose.




(c) Schaltzeitprognose und Autokorrektur.


Abbildung 5.9: Reisezeitgewinn in Abhängigkeit von der Streckenlänge, Art der Schaltzeitprognose, Routingstrategie. Reisezeitabweichungen im Bereich $[0,85;1,15]$.



(a) Perfekte Prognose (tatsächliche Schaltzeiten).



(b) Schaltzeitprognose.



(c) Schaltzeitprognose und Autokorrektur.

Abbildung 5.10: Reisezeitgewinn in Abhängigkeit von der Anzahl überquerrter Lichtsignalanlagen, Art der Schaltzeitprognose, Routingstrategie. Reisezeitabweichungen im Bereich $[0,85;1,15]$.

gnalanlagen auf der Route, vgl. Abbildung 5.10b.

Autokorrekturen durch Neuberechnung der ampeladaptiven Route bei Herausfallen aus dem Zeitfenster führen zu einer Erhöhung des Reisezeitgewinns im Vergleich zur Routenberechnung ohne Autokorrektur, vgl. Abbildungen 5.9c und 5.10c. Bei idealer Verkehrsabschätzung liegt der mittlere Reisezeitgewinn hier bei 5,19%. Bei einer Überschätzung um die Faktoren 0,9 und 0,85 werden Reisezeitgewinne um 4,28%, respektive 2,33% erzielt. Ampeladaptives Routing mit Autokorrektur kann im Testfeld auch bei einer Unterschätzung der Reisezeiten um die Faktoren 1,05 und 1,1 noch Reisezeitgewinne aufweisen (3,68% und 1,98%). Eine Unterschätzung um den Faktor 1,15 führt auch bei einer Autokorrektur der Route zu einem Reisezeitverlust (um 1,09%) im Vergleich zur Standardroute.

5.6 Zusammenfassung

In diesem Kapitel wurde ein Verfahren vorgestellt, mithilfe dessen es möglich ist, anhand des zukünftigen Schaltverhaltens von Lichtsignalanlagen optimierte Routenempfehlungen auszugeben. Primäres Ziel ist es hierbei, die Wartezeit an Lichtsignalanlagen zu minimieren und so die Reisezeit zu verkürzen. Es zeigte sich, dass derzeitige Navigationsgraphen eine Routingstrategie unter Einbeziehung zukünftiger Schaltzeiten nicht unterstützen. Zurückzuführen ist dies auf die Repräsentierung komplexer Kreuzungen durch mehrere Knoten in Verbindung mit der Funktionsweise des Standardlösungsverfahrens des kürzeste Wege Problems (A*-Algorithmus) auf Graphen. Zu Lösung wurde ein Algorithmus zur temporären, lokalen Knotenduplikation an komplexen Kreuzungen zur Laufzeit des A*-Algorithmus vorgestellt. Mithilfe dieses Algorithmus ist es möglich, eindeutige Kantenkombinationen individueller Abbiegebeziehungen an Kreuzungen zu generieren. Diese lokale Modifikationen des Ausgangsgraphen garantieren eine korrekte Suche des kürzesten Weges unter Berücksichtigung von Schaltzeitprognosen mit dem A*-Algorithmus. Ein signifikanter Anstieg der Berechnungszeit kann dabei ausgeschlossen werden, da eine komplexe Kreuzung mit 12 Kanten um maximal 20 neue Knoten erweitert wird.

Das ampeladaptive Routing wurde in einem großflächigen Testfeld von 100 km² im Münchner Zentrum bewertet. Bei der Evaluation wurden mehrere Aspekte berücksichtigt. Zum einen wurde der generell mögliche Reisezeitgewinn des ampeladaptiven Routings im Vergleich zur Standardroute unter idealen Bedingungen untersucht. Dazu wurden perfekte Prognosen in Form von tatsächlichen Schaltzeiten an den Lichtsignalanlagen im Testfeld verwendet und der Verkehr vernachlässigt. Dabei wurde ein mittlerer Reisezeitgewinn von 11,24% festgestellt. Ferner wurde untersucht, wie sich die Verwendung von den in den Kapiteln 3 und 4 erstellten Schaltzeitprognosen auf den Reisezeitgewinn auswirken. Dabei wurde auch deren Teilverfügbarkeit berücksichtigt, also die Tatsache, dass nicht immer Prognosen erstellt werden können. Hier ergab sich ein Reisezeitgewinn von etwa 5%. Weiterhin wurde die Verkehrssituation

in die Auswertung miteinbezogen. Untersucht wurde, welche Qualitätsanforderung an Echtzeitverkehrsinformationen gestellt werden muss, indem ermittelt wurde, bis zu welchem Grad Abweichungen von der geschätzten Reisezeit tolerierbar sind, um beim ampeladaptiven Routing einen Reisezeitgewinn zu erzielen. Hierzu wurden die Auswirkungen von Reisezeitabweichungen im Bereich $\pm 15\%$ $[0,85;1,15]$ auf den Reisezeitgewinn untersucht. Im betrachteten Testfeld lag der Reisezeitgewinn bei einer Reisezeitüberschätzung zwischen 2% und 12%. Eine Autokorrektur bei Herausfallen aus der ampeladaptiven Route führte dabei generell zu einer leichten Verbesserung des Ergebnisses. Eine Reisezeitunterschätzung führte zu einer deutlicheren Reduzierung des Reisezeitgewinns als eine Überschätzung. Hier lag ein Reisezeitgewinn nur bis zu einem Faktor von 1,1 vor, eine höhere Reisezeitunterschätzung führte zu einem leichten Reisezeitverlust (ca. 1%).

Die in diesem vorgestellten Kapitel erzielten Ergebnisse zeigen, dass bereits mit der gegebenen Infrastruktur und erzielbaren Prognosequalität ein ampeladaptives Routing einen Mehrwert bringen kann, wenn qualitativ hochwertige Echtzeitverkehrsinformationen, wie sie INRIX oder TomTom anbieten (vgl. Abschnitt 2.4), zur Verfügung stehen. Die Qualität der angebotenen Echtzeitverkehrsinformationen in innerstädtischen Bereichen kann nach dem derzeitigen Stand der Forschung jedoch noch nicht bewertet werden. Sie sind jedoch derzeit intensiver Forschungsgegenstand, auch im Fachbereich Verkehrsinformationsmanagement, Routenoptimierung der BMW Group. Bisherige Veröffentlichungen im Bereich der Qualitätsuntersuchung von Echtzeitverkehrsinformationen wie von Palmer et al. [88] legen jedoch den Schluss nahe, dass bereits jetzt, oder in naher Zukunft Fehlerbereiche von unter 15% erreicht werden können.

6 Zusammenfassung und Ausblick

6.1 Zusammenfassung und wissenschaftlicher Beitrag

Zunehmende Urbanisierung und steigender Mobilitätsbedarf stellen große Herausforderungen an Städte, aber auch Automobilhersteller. Hoher Zuzug auf begrenztem Raum wird die Mobilität einschränken, wenn nicht hinreichend reagiert wird. Mögliche Maßnahmen werden bereits erforscht und getestet, um nachhaltige Lösungen im Bereich der Mobilität und Sicherheit zu entwickeln. So arbeiten Städte, Kommunen, Automobilhersteller und Zulieferer gemeinsam an der Entwicklung neuer Konzepte zur vernetzten Mobilität. Ein Aspekt ist dabei die Verbesserung der Verkehrsabwicklung an Kreuzungen, indem durch Vernetzung und Kommunikation die Abwicklung flexibler und so effizienter gestaltet werden soll. Damit Fahrzeuge geeignet auf das Signalverhalten an Kreuzungen reagieren können, aber auch dem Fahrer passende Informationen und Unterstützungsfunktionen zur Verfügung gestellt werden können, muss das Signalverhalten an Kreuzungen bekannt sein. Ohne das Wissen über die voraussichtliche Dauer von Freigabe- und Sperrzeiten an den Lichtsignalanlagen auf der befahrenen Route können Funktionen wie die Restrotanzeige oder Geschwindigkeits- und Verzögerungsempfehlungen nicht bereitgestellt werden. Während die Forschung in der Bestimmung idealer Annäherungsmodelle bei bekannten zukünftigen Verhalten von Lichtsignalanlagen schon relativ weit vorangeschritten ist, vgl. Abschnitt 5.3.1, wurde der Aspekt der Schaltzeitprognose bisher eher vernachlässigt. Dies ist nicht zuletzt der Tatsache geschuldet, dass sich die Akquise umfangreicher Daten bisher als schwierig gestaltete, was auch für diese Arbeit eine Herausforderung darstellte.

In der vorliegenden Dissertation wurden unterschiedliche Beiträge zur Generierung von Schaltzeitprognosen auf Basis verschiedener (crowdsourcing-) Quellen erbracht. So wurde zum einen der Smart City-Gedanke einer mit den Fahrzeugen vernetzten Stadt zur Umsetzung diverser Ampelassistentenfunktionen aufgegriffen und anhand der Referenzstadt München technisch realisiert. Hierzu wurde in Kooperation mit dem KVR-München untersucht, welche Datenbestände für eine skalierbare Schaltzeitprognose nötig, aber auch aus System-sicht mit der aktuellen Hardwarestruktur in endlicher Zeit extrahierbar und übermittelbar sind. Weiterhin wurde ein skalierbares Konzept zur Prognose zu-

künftiger Schaltzeiten auf Basis der zyklisch übermittelten Daten entwickelt und evaluiert. Dieses Konzept wurde anderen Verfahren gegenübergestellt und konnte im Vergleich überzeugen.

Neben diesem Ansatz wurde mit der Schätzung von Freigabe- und Sperrzeiten aus der Analyse des Verhaltens von Fahrzeugen an Kreuzungen ein weiterer Beitrag zur Rekonstruktion aktueller und zukünftiger Signalzustände erbracht. Hierbei wurden als Basisdatensatz nicht mehr auf Schaltzeitinformationen von der Verkehrszentrale zurückgegriffen, sondern lediglich Daten aus dem Fahrzeugumfeld herangezogen. Konkret wurden hierbei Zeit- und Positionstempel aus der Floating Car Data-Technologie verwendet, um daraus Muster im Fahrverhalten zu erkennen, die Rückschlüsse auf das Signalverhalten von Lichtsignalanlagen zulassen. In diesem Zusammenhang wurden diverse Verhaltensmerkmale von Fahrzeugen im Kreuzungsbereich auf deren Signifikanz untersucht und die aussagekräftigsten mittels eines einfachen Bayesschen Netzes zusammengeführt. Mit dem entwickelten Verfahren kann der Rotstart von festzeitgesteuerten und leicht verkehrsabhängigen Lichtsignalanlagen mit einem RMSE von ± 4 Sekunden, der Grünstart mit einem RMSE von ± 2 Sekunden genau gelernt werden. Mit diesem Beitrag können überall Schaltzeitschätzungen durchgeführt werden, wo eine Akquise von Verkehrszentralen oder städtischen Verwaltungsstellen (sei es aus technischen oder datenschutzrechtlichen Gründen) nicht möglich ist.

Wichtig ist eine Qualitätsabsicherung der getätigten Prognosen, respektive Schaltzeitschätzungen. So ist eine Mindesteintretenswahrscheinlichkeit einer Schaltzeitprognose für viele Ampelassistentenfunktionen eine Voraussetzung. Beide vorgestellten Modelle können dies gewährleisten: So garantiert das in Kapitel 3 vorgestellte Verfahren mittels seines Rückkopplungssystems eine fortlaufende Überwachung der Qualität getätigter Prognosen. Das in Kapitel 4 beschriebene FCD-basierte Verfahren kann eine Qualitätssicherung über das individuelle Maß des Dafürhaltens der gelernten Umlaufzeit, sowie einer maximal zulässigen Standardabweichung einer Grün- respektive Rotstartschätzung tätigen.

Im letzten Abschnitt der vorliegenden Dissertation wurde ein Modell zur Optimierung von Routenempfehlungen anhand von Schaltzeitprognosen vorgestellt. Der Beitrag erstreckte sich dabei auf die Lösung von Unzulänglichkeiten der bestehenden Graphstruktur in Kartengraphen, als auch auf die Untersuchung des zu erwartenden Mehrwertes eines solchen Systems unter realistischen Bedingungen. Es zeigte sich hierbei, dass der Einbezug des Schaltverhaltens in die Routenberechnung bereits mit der gegebenen Infrastruktur und der erreichbaren Prognosequalität zu einem Reisezeitgewinn führt. Maßgeblich für die Höhe des Reisezeitgewinns ist dabei die Qualität von Schaltzeitprognosen, sowie der Echtzeitverkehrsinformationen auf den alternativen Routen.

6.2 Ausblick

Der Trend konkreter Maßnahmen im Rahmen der Smart City Bestrebungen ist noch nicht abzusehen. Allerdings ist es wahrscheinlich, dass Städte die Kommunikation und Interaktion mit den Fahrzeugen vorantreiben und Daten in größerem Umfang als bisher mit Partnern austauschen. Ein erster Meilenstein in diesem Kontext sind Modelle wie der Mobilitäts Daten Marktplatz, in dem eine breite Menge von Verkehrsdaten - etwa Staus, Parkplätze, Verkehrsströme, aber auch Schaltzeitinformationen - ausgetauscht werden sollen. Denkbar ist auch, dass Städte in Zukunft selbst bestehende Daten verarbeiten und ihre Verkehrsinfrastruktur dynamisch auf aktuelle Situationen optimieren. Diskutiert werden überdies auch tiefer vernetzte Ansätze, in welchen die Kommunikation zum Fahrzeug weiter ausgebaut und Fahrzeuge als mobile Sensoren verwendet werden. Im Uplink sollen Fahrzeuge Städten und Verkehrszentralen Positionsdaten zur Verfügung stellen, auf Basis derer diese die Verkehrsströme besser steuern könnten, indem die Signalparameter von Lichtsignalanlagen entsprechend angepasst werden. Im Gegenzug werden den Fahrzeugen im Dowlink Informationen wie Schaltzeitprognosen geliefert.

Städte und Automobilbranche können von den Innovationen der zunehmenden Digitalisierung profitieren und müssen die sich ergebenden Möglichkeiten nutzen, um die Herausforderungen der steigenden Verkehrsbelastung zu meistern. Eine Möglichkeit stellen intelligente Assistenzfunktionen speziell im Kreuzungsbereich dar. Diese Arbeit liefert verschiedene Beiträge zur Umsetzung der Ampelassistentenfunktion im Fahrzeug. Die hier behandelten Fragestellungen und die gesammelten Erkenntnisse und Resultate bieten aber auch das Potential für weitere Forschungsarbeiten:

- Die Verfügbarkeit von Schaltzeitprognosen ermöglicht es, eine Vielzahl von Ampelassistentenfunktionen im Fahrzeug anzubieten. Speziell Funktionen, welche ideale Annäherungsstrategien an Kreuzungen nutzen, wie die Grünband-Geschwindigkeitsempfehlung, oder teilautomatisierte Eingriffe in die Längsregelung, können ab einer gewissen Ausstattungsrate von Fahrzeugen den Durchfluss des Verkehrsnetzes erhöhen. Durch eine ideale Annäherung an Kreuzungen können viele Stopps vermieden werden. So können der Rückstau reduziert und der Durchfluss gesteigert werden. Weiter können auch Reaktionszeiten wartender Fahrer durch Ampelassistentenfunktionen (z.B. Restrotanzeige oder teilautomatisierte Beschleunigung) gesenkt werden. Ferner wird sich durch eine Vermeidung von Stopps und dadurch bedingter Wiederbeschleunigungen die CO₂-Emission der Fahrzeuge reduzieren. Die sich hier ergebenden Potentiale eröffnen vielerlei Forschungsmöglichkeiten.
- Das ampeladaptive Routing als eine Ausprägungsform der Ampelassistentenz wurde im Rahmen dieser Arbeit unter der Prämisse einer geringen Ausstattungsrate untersucht. Auch hier ergeben sich weitere interessante

Forschungsaspekte, wenn man von einer großflächigen Anwendung dieser Funktion ausgeht. Vor allem der flexible Charakter von ampeladaptiven Routenempfehlungen kann Auswirkungen auf den Verkehrsfluss haben. Eine wichtige Forschungsfrage ist, wie eine sinnvolle Vernetzung und ein Informationsaustausch zwischen den individuellen Routingapplikationen ausgestaltet wird, um eine gleichmäßige Ausnutzung des Straßennetzes zu garantieren.

- Der im Rahmen dieser Arbeit vorgestellte Ansatz zur crowdsourcingbasierten Schaltzeitprognose verwendet die aktuell verfügbaren Informationen im Fahrzeug. Zukünftig werden weitere Quellen und neue Technologien hinzukommen, welche die Qualität von Schaltzeitprognosen weiter verbessern können. Hierzu gehört insbesondere die Kamera-Technologie. Aktuelle Bildverarbeitungsalgorithmen sind bereits in der Lage, Signalzustände von Lichtsignalanlagen in Echtzeit anhand von Kameradaten zu erkennen. Im Vergleich zu der FCD Technologie ist diese Informationsquelle sehr viel genauer, weshalb eine genauere Schaltzeitrekonstruktion möglich sein kann. Sobald diese Technologie verfügbar ist, kann man diese Daten hinsichtlich der Verbesserung von Signalzustandsschätzungen untersuchen. Darüber hinaus ist es denkbar, dass in Zukunft kamera- und FCD-basierte Informationen in Echtzeit zur Verfügung stehen. Auf diesem Wege können Schaltzeitinformationen zwischen den Fahrzeugen ebenfalls in Echtzeit ausgetauscht werden.

Für die Zukunft ist geplant, aufbauend auf den Ergebnissen dieser Arbeit die Möglichkeiten kamerabasierter Schaltzeitprognosen, sowie das Potential der Echtzeitverfügbarkeiten von Fahrzeugdaten weiter zu erforschen.

Literaturverzeichnis

- [1] BMW Group Press Club Global, “Press Release: AUDI AG, BMW Group and Daimler AG agree with Nokia Corporation on joint acquisition of HERE digital mapping business,” 2015.
- [2] “Zentrum für Smart Cities.” Online, 2016. <http://www.ict-smart-cities-center.com/>, letzter Abruf: 29.01.2016.
- [3] D. Washburn, U. Sindhu, S. Balaouras, R. Dines, N. Hayes, and L. Nelson, “Helping CIOs understand Smart City initiatives,” *Growth*, vol. 17, p. 2, 2009.
- [4] U. Consortium, “Urban space: User oriented assistance systems and network management,” 2014.
- [5] “Europas Regionen im Kampf gegen den Klimawandel.” Online, 2010. <http://www.euractiv.de/energie-und-klimaschutz/linkdossier/europas-regionen-im-kampf-gegen-den-klimawandel-000121>, letzter Abruf: 28.01.2016.
- [6] I. Iglesias, L. Isasi, M. Larburu, V. Martinez, and B. Molinete, “I2V Communication Driving Assistance System: On-Board Traffic Light Assistant,” in *Vehicle Technology Conference, 2008. VTC 2008-Fall. IEEE 68th*, pp. 1–5, Sept 2008.
- [7] “Die EU-Verordnung zur Verminderung der CO₂ - Emissionen von Personenkraftwagen,” 2009.
- [8] C. Kennedy, S. Demoullin, and E. Mohareb, “Cities reducing their greenhouse gas emissions,” *Energy Policy*, vol. 49, pp. 774 – 777, 2012. Special Section: Fuel Poverty Comes of Age: Commemorating 21 Years of Research and Policy.
- [9] “Unsere Fahrzeuge müssen mindestens so viel besser sein, wie sie teuer sind.” Online, 2016. http://www.pwc.de/de/automobilindustrie/unsere-fahrzeuge-muessen-mindestens-so-viel-besser-sein_wie-sie-teuer-sind.html, letzter Abruf: 02.02.2016.
- [10] H. Xia, K. Boriboonsomsin, F. Schweizer, A. Winckler, K. Zhou, W.-B. Zhang, and M. Barth, “Field operational testing of ECO-approach technology at a fixed-time signalized intersection,” in *Intelligent Transportation*

- Systems (ITSC), 2012 15th International IEEE Conference on*, pp. 188–193, Sept 2012.
- [11] G. Mahler and A. Vahidi, “Reducing idling at red lights based on probabilistic prediction of traffic signal timings,” in *American Control Conference (ACC), 2012*, pp. 6557–6562, IEEE, 2012.
- [12] G. Mahler and A. Vahidi, “An Optimal Velocity-Planning Scheme for Vehicle Energy Efficiency Through Probabilistic Prediction of Traffic-Signal Timing,” *Intelligent Transportation Systems, IEEE Transactions on*, vol. 15, pp. 2516–2523, Dec 2014.
- [13] D. Eckhoff, B. Halmos, and R. German, “Potentials and limitations of Green Light Optimal Speed Advisory systems, year=2013,” in *Vehicular Networking Conference (VNC), 2013 IEEE*, pp. 103–110, Dec.
- [14] VERORDNUNG (EG) Nr. 443/2009 DES EUROPÄISCHEN PARLAMENTS UND DES RATES vom 23. April 2009 zur Festsetzung von Emissionsnormen für neue Personenkraftwagen im Rahmen des Gesamtkonzepts der Gemeinschaft zur Verringerung der CO₂-Emissionen von Personenkraftwagen und leichten Nutzfahrzeugen.
- [15] C. Ernst, L. Eckstein, and I. Olschewski, “CO₂-Reduzierungspotenziale bei Pkw bis 2020,” *Abschlussbericht Dezember*, 2012.
- [16] E. Donges, “A conceptual framework for active safety in road traffic,” *Vehicle System Dynamics*, vol. 32, no. 2-3, pp. 113–128, 1999.
- [17] T. M. Gasser, C. Arzt, M. Ayoubi, A. Bartels, L. Bürkle, J. Eier, F. Flemisch, D. Häcker, T. Hesse, W. Huber, *et al.*, “Rechtsfolgen zunehmender Fahrzeugautomatisierung,” *BERICHTE DER BUNDESANSTALT FUER STRASSENWESEN. UNTERREIHE FAHRZEUG-TECHNIK*, no. 83, 2012.
- [18] H. Winner, S. Hakuli, and G. Wolf, *Handbuch Fahrerassistenzsysteme*. Springer, 2009.
- [19] “Mobilitäts Daten Marktplatz.” Online, 2007. <http://www.mdm-portal.de/>, letzter Abruf: 05.02.2016.
- [20] B. Friedrich, “Kooperative Lichtsignaloptimierung - Bayerisches Pilotprojekt.” Online, 2010. <http://www.kolibri-projekt.de/index.html>, letzter Abruf: 03.02.2016.
- [21] W. Scholl, “Adaptive und kooperative Technologien für den intelligenten Verkehr.” Online, 2007. <http://www.aktiv-online.org/index.html>, letzter Abruf: 03.02.2016.

-
- [22] E. GmbH, schmidt-works GmbH, and A.-D. S. GmbH, "Sichere Intelligente Mobilität Testfeld Deutschland." Online, 2011. <http://www.simtd.de/index.dhtml/deDE/index.html>, letzter Abruf: 03.02.2016.
- [23] G. software, "TRAVOLUTION in Ingolstadt." Online, 2008. <http://www.travolution-ingolstadt.de/>, letzter Abruf: 03.02.2016.
- [24] A.-C. Bartölke, "Kooperative und optimierte Lichtsignalsteuerung in städtischen Netzen." Online, 2009. <http://www.projekt-koline.de/>, letzter Abruf: 03.02.2016.
- [25] *Richtlinien für Lichtsignalanlagen*. Forschungsgesellschaft für Strassen- und Verkehrswesen-Verlag, 2010.
- [26] "Advice Leaflet 1: The SSCOOT Urban Traffic Control System." Online, 2016. <http://www.scoot-utc.com>, letzter Abruf: 28.01.2016.
- [27] P. Hunt, D. Robertson, R. Bretherton, and R. Winton, "SCOOT-a traffic responsive method of coordinating signals," tech. rep., 1981.
- [28] K. Wood, "Urban traffic control: Systems review," *Project report; 41*, 1993.
- [29] "SCATS 6 Functional Description." Online, 2016. <http://www.scats.com.au/support-resources.html>, letzter Abruf: 28.01.2016.
- [30] D. Kobbeloer, *Dezentrale Steuerung von Lichtsignalanlagen in urbanen Verkehrsnetzen*. PhD thesis, Institut für Verkehrswesen, Universität Kassel, 34109 Kassel, 2007.
- [31] Federal Highway Administration, "Traffic Signal Timing Manual," 2013.
- [32] R. L. Gordon and W. Tighe, *Traffic Control System Handbook*. Dunn Engineering Associates In association with Siemens Intelligent Transportation Systems, 2005.
- [33] I. Stamatakis, "Traffic light prediction and analysis of the related data availability and usability for different types of traffic light assistance services," Master's thesis, Technische Universität München - Lehrstuhl für Verkehrstechnik, 2014.
- [34] S. Breitenberger, B. Gruber, and M. Neuherz, "Extended Floating Car Data - Potenziale für die Verkehrsinformation und notwendige Durchdringungsraten," *Straßenverkehrstechnik*, vol. 48, no. 10, pp. 522–531, 2004.
- [35] M. Strassberger, "Kontextbereitstellung in Automobilen Ad-hoc Netzen." 2007.

- [36] “FCD (Floating Car Data).” Online, 2015. <http://www.itwissen.info/definition/lexikon/floating-car-data-FCD.html>, letzter Abruf: 9.9.2015.
- [37] J. Schlaich, “Nutzungsmöglichkeiten von Floating Phone Data,” in *9. Fachkolloquium Straße und Verkehr 2005*, Lehrstuhl für Verkehrsplanung und Verkehrsleittechnik, 2005.
- [38] Y. Zheng and X. Zhou, *Computing with spatial trajectories*. Springer Science & Business Media, 2011.
- [39] W. Huber, M. Lädke, and R. Ogger, “Extended floating-car data for the acquisition of traffic information,” in *Proceedings of the 6th World congress on intelligent transport systems*, pp. 1–9, 1999.
- [40] “Ermittlung von Fahrmustern auf der Grundlage von Taxi-FCD.” Online, 2015. <https://bitre.gov.au/events/2014/files/NewDataSources-BackgroundPaper-April>, letzter Abruf: 24.9.2015.
- [41] “INRIX Real-Time Traffic Data.” Online, 2015. <http://inrix.com/industry/automotive/>, letzter Abruf: 25.9.2015.
- [42] “INRIX Traffic App.” Online, 2015. <http://inrix.com/inrix-traffic-app/>, letzter Abruf: 25.9.2015.
- [43] N. Cohn and H. Bischoff, “Floating car data for transportation planning.” Online, 2015. <http://onlinepubs.trb.org/onlinepubs/conferences/2012/NATMEC/Cohn.pdf>, letzter Abruf: 24.9.2015.
- [44] “How does AirSage gather locations.” Online, 2015. <http://www.airsage.com/Industries/Transportation/FAQ/>, letzter Abruf: 24.9.2015.
- [45] “Waze.” Online, 2015. <https://www.waze.com>, letzter Abruf: 25.9.2015.
- [46] T. Jeske, “Floating car data from smartphones: what google and waze know about you and how hackers can control traffic,” *Proc. of the BlackHat Europe*, 2013.
- [47] “nextbus.” Online, 2015. <https://www.nextbus.com>, letzter Abruf: 22.9.2015.
- [48] M. Rahmani, H. Koutsopoulos, and A. Ranganathan, “Requirements and potential of GPS-based floating car data for traffic management: Stockholm case study,” in *Intelligent Transportation Systems (ITSC), 2010 13th International IEEE Conference on*, pp. 730–735, Sept 2010.

-
- [49] W. Schmidt, “Ermittlung von Fahrmustern auf der Grundlage von Taxi-FCD.” Online, 2015. <http://www.umwelt.sachsen.de/umwelt/>, letzter Abruf: 24.9.2015.
- [50] “Cabspotting.” Online, 2015. <http://cabspotting.org>, letzter Abruf: 24.9.2015.
- [51] S. Fayazi, A. Vahidi, G. Mahler, and A. Winckler, “Traffic Signal Phase and Timing Estimation From Low-Frequency Transit Bus Data,” *Intelligent Transportation Systems, IEEE Transactions on*, vol. 16, pp. 19–28, Feb 2015.
- [52] E. W. Dijkstra, “A note on two problems in connexion with graphs,” *Numerische mathematik*, vol. 1, no. 1, pp. 269–271, 1959.
- [53] P. E. Hart, N. J. Nilsson, and B. Raphael, “A formal basis for the heuristic determination of minimum cost paths,” *Systems Science and Cybernetics, IEEE Transactions on*, vol. 4, no. 2, pp. 100–107, 1968.
- [54] P. Sanders and D. Schultes, “Engineering fast route planning algorithms,” in *Experimental Algorithms*, pp. 23–36, Springer, 2007.
- [55] K. Ishikawa, M. Ogawa, S. Azuma, and T. Ito, “Map navigation software of the electro-multivision of the’91 Toyota Soarer,” in *Vehicle Navigation and Information Systems Conference, 1991*, vol. 2, pp. 463–473, IEEE, 1991.
- [56] D. Schultes, “Route Planning in Road Networks.,” in *Ausgezeichnete Informatikdissertationen*, pp. 271–280, 2008.
- [57] P. Sanders and D. Schultes, “Highway hierarchies hasten exact shortest path queries,” in *Algorithms–Esa 2005*, pp. 568–579, Springer, 2005.
- [58] P. Sanders and D. Schultes, “Engineering highway hierarchies,” in *Algorithms–ESA 2006*, pp. 804–816, Springer, 2006.
- [59] J. Arz, D. Luxen, and P. Sanders, “Transit node routing reconsidered,” in *Experimental Algorithms*, pp. 55–66, Springer, 2013.
- [60] H. Bast, S. Funke, and D. Matijevic, “Ultrafast shortest-path queries via transit nodes,” *The Shortest Path Problem: Ninth DIMACS Implementation Challenge*, vol. 74, pp. 175–192, 2009.
- [61] H. Bast, S. Funke, D. Matijevic, P. Sanders, and D. Schultes, “In Transit to Constant Time Shortest-Path Queries in Road Networks.,” in *ALLENEX*, SIAM, 2007.

- [62] E. Koukoumidis, L.-S. Peh, and M. R. Martonosi, “SignalGuru: leveraging mobile phones for collaborative traffic signal schedule advisory,” in *Proceedings of the 9th international conference on Mobile systems, applications, and services*, pp. 127–140, ACM, 2011.
- [63] T. Weisheit, “Algorithmenentwicklung zur Prognose von Schaltzeitpunkten an verkehrsabhängigen Lichtsignalanlagen,” in *HEUREKA*, 2014.
- [64] A. Kagoshima, N. Sio, and K. K. Das, “Pivotal Data Science Lab Traffic Light Deep Dive.” 4 2013.
- [65] V. Protschky, “Verfahren zur Prognose des Verhaltens von verkehrsadaptiven Ampelverkehrsknoten mithilfe von Historiendaten,” Master’s thesis, Ludwig-Maximilians-Universität München, 2013.
- [66] “Python Language Reference, version 2.7.” Online. <http://www.python.org>.
- [67] “Lichtsignalanlagen und Verkehrssteuerung.” Online, 2015. <https://www.stuttgart.de/item/show/358750>, letzter Abruf: 9.9.2015.
- [68] G. Hoffmann *et al.*, “Beschreibung von Verkehrsabläufen an signalisierten Knotenpunkten,” *Forschung Straßenbau und Straßenverkehrstechnik*, no. 693, 1994.
- [69] R. Akçelik and M. Besley, “Queue discharge flow and speed models for signalised intersections,” in *Transportation and Traffic Theory in the 21st Century, Proceedings of the 15th International Symposium on Transportation and Traffic Theory*, pp. 99–118, 2002.
- [70] M. Ramezani and N. Geroliminis, “Queue Profile Estimation in Congested Urban Networks with Probe Data,” *Computer-Aided Civil and Infrastructure Engineering*, 2014.
- [71] X. Ban, R. Herring, P. Hao, and A. Bayen, “Delay pattern estimation for signalized intersections using sampled travel times,” *Transportation Research Record: Journal of the Transportation Research Board*, no. 2130, pp. 109–119, 2009.
- [72] G. Comert and M. Cetin, “Queue length estimation from probe vehicle location and the impacts of sample size,” *European Journal of Operational Research*, vol. 197, no. 1, pp. 196–202, 2009.
- [73] P. Krijger, “Traffic Light Prediction for Tom Tom Devices,” Master’s thesis, 2013.
- [74] W. W.-S. Wei, *Time series analysis*. Addison-Wesley publ, 1994.

-
- [75] E. W. Weisstein, “Uniform Distribution.” Online, 2015. <http://mathworld.wolfram.com/UniformDistribution.html>, letzter Abruf: 22.9.2015.
- [76] R. A. Fisher, *Statistical methods for research workers*. Genesis Publishing Pvt Ltd, 1925.
- [77] I. H. Witten and E. Frank, *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2005.
- [78] R. G. Miller Jr, *Beyond ANOVA: basics of applied statistics*. CRC Press, 1997.
- [79] M. Kerper, C. Wewetzer, A. Sasse, and M. Mauve, “Learning Traffic Light Phase Schedules from Velocity Profiles in the Cloud,” in *New Technologies, Mobility and Security (NTMS), 2012 5th International Conference on*, pp. 1–5, May 2012.
- [80] D. Krajzewicz, G. Hertkorn, C. Rössel, and P. Wagner, “Sumo (simulation of urban mobility),” in *Proc. of the 4th middle east symposium on simulation and modelling*, pp. 183–187, 2002.
- [81] C. Ruhhammer, N. Hirsenkorn, F. Klanner, and C. Stiller, “Crowdsourced intersection parameters: A generic approach for extraction and confidence estimation,” in *Intelligent Vehicles Symposium Proceedings, 2014 IEEE*, pp. 581–587, June 2014.
- [82] N. Z. Mohammed, A. Ghazi, and H. E. Mustafa, “Positional accuracy testing of google earth,” *International Journal of Multidisciplinary Sciences and Engineering*, vol. 4, no. 6, 2013.
- [83] R. Adams and L. Bischof, “Seeded region growing,” *Transactions on Pattern Analysis and Machine Intelligence, IEEE*, vol. 16, pp. 641–647, Jun 1994.
- [84] S. S. Shapiro and M. B. Wilk, “An analysis of variance test for normality (complete samples),” *Biometrika*, pp. 591–611, 1965.
- [85] “Datasheet: Navilock NL-602U USB 2.0 GPS Receiver u-blox 6.” Online, 2015. <http://www.navilock.com/produkt/61840/pdf.html?sprache=en>, letzter Abruf: 9.11.2015.
- [86] RICHTLINIE 2010/40/EU DES EUROPÄISCHEN PARLAMENTS UND DES RATES vom 7. Juli 2010 zum Rahmen für die Einführung intelligenter Verkehrssysteme im Straßenverkehr und für deren Schnittstellen zu anderen Verkehrsträgern (ABl. L 207/1 vom 6.8.2010).

- [87] IVSG - Intelligente Verkehrssysteme Gesetz. Gesetz über Intelligente Verkehrssysteme im Straßenverkehr und deren Schnittstellen zu anderen Verkehrsträgern - Gesetz über Intelligente Verkehrssysteme im Straßenverkehr und deren Schnittstellen zu anderen Verkehrsträgern vom 11. Juni 2013 (BGBl. I Nr. 29 vom 20.06.2013 S. 1553;::31.08.2015 S. 1474 15) Gl.-Nr.: 9231-13
- [88] J. Palmer and H. Rehborn, "Reconstruction Quality of Congested Freeway Traffic Patterns from Probe Vehicles Based on Kerner's Three-Phase Traffic Theory," *International Journal on Advances in Systems and Measurements* (4), pp. 168–181, 2011.
- [89] B. Asadi and A. Vahidi, "Predictive use of traffic signal state for fuel saving," in *Control in Transportation Systems*, pp. 484–489, 2009.
- [90] B. Asadi and A. Vahidi, "Predictive cruise control: Utilizing upcoming traffic signal information for improving fuel economy and reducing trip time," vol. 19, pp. 707–714, IEEE, 2011.
- [91] G. De Nunzio, C. Canudas de Wit, P. Moulin, and D. Di Domenico, "Eco-driving in urban traffic networks using traffic signal information," in *Decision and Control (CDC), 2013 IEEE 52nd Annual Conference on*, pp. 892–898, Dec 2013.
- [92] L. Zurbuchen, "Geographisches Informationssystem GIS-ZH, Geometadaten - GeoLion." Online, 2015. <http://www.geolion.zh.ch/geodatenservice/show?nbid=1260>, <http://maps.zh.ch/?topic=TBAVMSZH>, letzter Abruf: 11.12.2015.
- [93] V. Tyagi, S. Kalyanaraman, and R. Krishnapuram, "Vehicular Traffic Density State Estimation Based on Cumulative Road Acoustics," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 13, pp. 1156–1166, Sept 2012.
- [94] I. Kaparias, M. G. H. Bell, H. Belzner, A. Leonhardt, and K. Bogenberger, "Zuverlässige Dynamische Zielführung," *Straßenverkehrstechnik*, no. 9, pp. S. 574–581, 2009.
- [95] A. Leonhardt, "Ein instanzbasiertes Lernverfahren zur Schätzung und Prognose von Verkehrskenngrößen unter Nutzung räumlich-zeitlicher Verkehrsmuster," In: *Straßenverkehrstechnik*, vol. 54, pp. 87–95, 2010.
- [96] S. Grubwinkler, M. Hirschvogel, and M. Lienkamp, "Driver- and situation-specific impact factors for the energy prediction of EVs based on crowd-sourced speed profiles," in *Intelligent Vehicles Symposium Proceedings, 2014 IEEE*, pp. 1069–1076, June 2014.

- [97] J. Apple, P. Chang, A. Clauson, H. E. Dixon, H. Fakhoury, M. L. Ginsberg, E. Keenan, A. Leighton, K. Scavozze, and B. Smith, “Green Driver: AI in a Microcosm.,” in *AAAI*, 2011.
- [98] D. Capovilla, “What could you do if you knew when the traffic lights would change?.” Online, 2015. <https://connectedsignals.com/>, letzter Abruf: 11.12.2015.

Eigene Veröffentlichungen

- [99] V. Protschky, C. Ruhhammer, and S. Feit, “Learning Traffic Light Parameters with Floating Car Data,” in *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 2438–2443, Sept 2015.
- [100] V. Protschky, S. Feld, and M. Walischmiller, “Traffic Signal Adaptive Routing,” in *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 450–456, Sept 2015.
- [101] V. Protschky, S. Feit, and C. Linnhoff-Popien, “On the Potential of Floating Car Data for Traffic Light Signal Reconstruction,” in *Vehicular Technology Conference (VTC Spring), 2015 IEEE 81st*, pp. 1–5, May 2015.
- [102] V. Protschky, P. Seifert, and S. Feit, “Stop Line Detection Using Satellite-Image Segmentation,” in *Vehicular Technology Conference (VTC Spring), 2015 IEEE 81st*, pp. 1–5, May 2015.
- [103] V. Protschky and S. Feit, “Traffic Light Assistance – Ein innovativer Mobilitätsdienst im Fahrzeug,” in *Marktplätze im Umbruch* (C. Linnhoff-Popien, M. Zaddach, and A. Grahl, eds.), Xpert.press, pp. 579–587, Springer Berlin Heidelberg, 2015.
- [104] D. Irschik, V. Protschky, and F. Schweizer, “Kooperative Systeme im Strassenverkehr auf Basis einer Client-Server-Architektur/Cooperative traffic services using client-server architecture,” *Strassenverkehrstechnik*, vol. 58, no. 10, 2014.
- [105] V. Protschky, S. Feit, and C. Linnhoff-Popien, “Extensive Traffic Light Prediction under Real-World Conditions,” in *Vehicular Technology Conference (VTC Fall), 2014 IEEE 80th*, pp. 1–5, Sept 2014.
- [106] V. Protschky, K. Wiesner, and S. Feit, “Adaptive traffic light prediction via Kalman filtering,” in *Intelligent Vehicles Symposium Proceedings, 2014 IEEE*, pp. 151–157, June 2014.
- [107] M. Dürr, V. Protschky, and C. Linnhoff-Popien, “Modeling Social Network Interaction Graphs,” in *Proceedings of the 2012 International Conference on Advances in Social Networks Analysis and Mining (ASONAM 2012)*, ASONAM ’12, (Washington, DC, USA), pp. 660–667, IEEE Computer Society, 2012.

Abkürzungsverzeichnis

AA Ampeladaptiv

ACC Autonomous Cruise Control

AKTIV Adaptive und kooperative Technologien für den intelligenten Verkehr

ANOVA Analysis of Variance

BaST Bundesanstalt für Straßenwesen

FCD Floating Car Data

FPD Floating Phone Data

FTP File Transfer Protocol

GPS Global Positioning System

GSM Global System for Mobile Communications

HY Hypothesentest zur Umlaufzeitrekonstruktion

KF Kalman Filter

KK Korrelationskoeffizient

KKR Korrektklassifikationsrate

KOLIBRI Kooperative Lichtsignaloptimierung -Bayerisches Pilotprojekt

KOLINE Kooperative und optimierte Lichtsignalsteuerung in städtischen Netzen

KVR Kreisverwaltungsreferat

LK Leere-Koeffizient

LSA Lichtsignalanlage

LTE Long Term Evolution

MDM Mobilitätsdatenmarkt

- MSA** Motor-Start-Stopp-Automatik
- RILSA** Richtlinien für Lichtsignalanlagen
- RMSE** Root-Mean-Square Error
- RS** Rückkopplungssystem
- SCATS** Sydney Coordinated Adaptive Traffic System
- SCOOT** Split Cycle Offset Optimisation Technique
- SG** Signalgruppe
- Sim-TD** Sichere intelligente Mobilität Testfeld Deutschland
- SUMO** Simulation of Urban MObility
- SVM** Support Vector Machine
- UMTS** Universal Mobile Telecommunications System
- UR:BAN** Urbaner Raum: Benutzergerechte Assistenzsysteme und Netzmanagement
- VB** Minimierung der Varianz von Beschleunigungspunkten
- VH** Varianzminimierung von Haltelinienüberquerungen
- VZ** Varianz der Zeitdifferenzen
- WZ** Weg-Zeit
- XFCD** Extended Floating Car Data