



Lehrstuhl für Verkehrstechnik
Technische Universität München
Univ.-Prof. Dr.-Ing. Fritz Busch

Schriftenreihe Heft 7

Heidrun Belzner

Erkennung von Verkehrsstörungen unter Verwendung
erweiterter fahrzeuggenerierter Daten

München 2009

Die Deutsche Bibliothek – CIP Einheitsaufnahme

Belzner, Heidrun:

Erkennung von Verkehrsstörungen unter Verwendung
erweiterter fahrzeuggenerierter Daten

Schriftenreihe des Lehrstuhls für Verkehrstechnik
der Technischen Universität München, Heft 7

Zugl.: München, Techn. Univ., Diss., 2007

ISBN 978-3-937631-07-3

Copyright ©

Lehrstuhl für Verkehrstechnik der Technischen Universität München 2009

Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder
vollständigen Wiedergabe, der Speicherung in Datenverarbeitungsanlagen und
der Übersetzung, vorbehalten.

Druck: TypeSet GmbH, Ismaning

ISBN 978-3-937631-07-3

ISSN 1612-9431

Lehrstuhl für Verkehrstechnik · Institut für Verkehrswesen

Technische Universität München · 80333 München

Telefon: 089 / 289 – 22438, Telefax: 089 / 289 - 22333, E-Mail: info@vt.bv.tum.de

Internet: www.vt.bv.tum.de

Bei der vorliegenden Veröffentlichung handelt es sich um die Dissertation von
Frau Dr. rer. nat. Heidrun Belzner

Vorsitzender: Univ.-Prof. Dr.-Ing. Dr.-Ing. habil. G. Leykauf, TU München

Prüfer der Dissertation:

1. Univ.-Prof. Dr.-Ing., Fritz Busch, TU München
2. Univ.-Prof. Dr. rer. nat. Dr. rer. nat. habil. T. Huckle,
TU München

Danksagung

Ich möchte allen Personen danken, die mich während der letzten drei Jahre unterstützt haben. Allen voran gilt mein Dank meinen Gutachtern Herrn Prof. Dr. Busch und Herrn Prof. Dr. Huckle für die Betreuung meiner Dissertation.

Die Arbeit entstand im Wesentlichen in der Abteilung EW-1 der BMW Group. Hier möchte ich mich vor allem bei Herrn Dr. Lerner bedanken, der diese Arbeit ermöglicht und mir den nötigen Freiraum für ihre Bearbeitung gelassen hat. Vielen Dank auch an alle Mitarbeiter von EW-1 für Ihre Unterstützung!

Mein besonderer Dank gilt Herrn Dr. Bogenberger für die hervorragende und lehrreiche Betreuung. Ohne seine Unterstützung und seine Förderung wäre diese Arbeit sicherlich nicht zustande gekommen.

Mein spezieller Dank gilt Herrn Dr. Ronald Kates für seine inhaltliche Unterstützung und seine Fähigkeit, den Finger auf die Wunde zu legen. Die Diskussionen mit ihm gaben mir stets die nötigen Impulse und Ideen, um weiter zu kommen.

Herzlichen Dank an meine Leser und Korrektoren Axel Leonhardt, Andrea Holz, Jeanette Hübner und Daniel! Ebenso gilt mein Dank allen Mitarbeitern am Lehrstuhl für Verkehrstechnik der TU München für Ihre Unterstützung! Ohne sie wäre mein Algorithmus vielleicht immer noch namenlos!

Schließlich möchte ich mich bei meiner Familie bedanken, die mich immer unterstützt hat. Besonders meiner Mutter danke ich für das Korrekturlesen.

Zuletzt möchte ich meinem Freund Daniel danken, der mit mir Rückschläge und Erfolge teilte und mir immer die notwendige Kraft gab, weiter zu machen. Inzwischen ist auch er ein kleiner Experte in diesem Bereich.

Seefeld, Januar 2007

Heidrun Belzner

Inhaltsverzeichnis

1. Einleitung	1
1.1. Kontext und Zielsetzung	1
1.2. Gewählter Ansatz	3
1.3. Aufbau der Arbeit	4
2. Individuelle Verkehrsinformation und Datenerfassung	6
2.1. Arten von Verkehrsinformationen	6
2.2. Meldekette	7
2.3. Erfassung von Verkehrsdaten	10
2.3.1. Stationäre Datenerfassung	10
2.3.2. Fahrzeugseitige Datenerfassung	11
2.3.3. Sonstige Arten der Datenerfassung	14
2.4. Fazit	16
3. Verkehrliche Grundlagen und Verkehrsstörungen	17
3.1. Verkehrsstörungen	17
3.1.1. Begriff der Verkehrsstörung	17
3.1.2. Beschreibung des Verkehrsablaufs	18
3.2. Verkehrliche Kenngrößen und Deskriptoren	19
3.2.1. Mikroskopische Betrachtung	19
3.2.2. Makroskopische Betrachtung	24
3.3. Definition von Verkehrsstörungen	28
3.3.1. Makroskopische Definitionen	29
3.3.2. Diskussion der Deskriptoren	36
3.3.3. Mikroskopische Definition	38
4. Erkennung von Verkehrsstörungen	41
4.1. Begriff der Störungserkennung	41
4.2. Verfahren auf Basis stationärer Datenquellen	42
4.3. Verfahren auf Basis von FCD	52
4.3.1. Bakengestützte Verfahren	53
4.3.2. Mobilfunkgestützte Verfahren	54
4.4. Verfahren auf Basis von XFCD	56

4.4.1. Fuzzy-Algorithmus	56
4.4.2. Incognito	58
4.4.3. City-Algorithmus	59
4.4.4. Schwellenwertverfahren	60
4.5. Luft- und personen-basierte Verfahren	61
4.6. Schlussfolgerungen	62
5. SWIM – Stoßwellen Erkennung mittels Interventionsmodell	64
5.1. Anforderungen an den Algorithmus und gewählter Ansatz	64
5.2. Einführung in die Zeitreihenanalyse	67
5.2.1. ARIMA-Modell	67
5.2.2. Modellbildung	69
5.3. ARIMA-Modell für den ungestörten Verkehr	70
5.3.1. Entwicklungsszenario	71
5.3.2. Modellidentifikation	72
5.3.3. Parameterschätzung und diagnostische Überprüfung	73
5.4. Interventionsanalyse	77
5.4.1. Erkennung von Änderungen im Geschwindigkeitsniveau – M1	77
5.4.2. Erkennung von Ausreißern und starken Geschwindigkeitsgefällen – M2	81
5.5. Aufbau und Funktionsweise von SWIM	82
5.5.1. Erkennung der Störungseinfahrt und der instabilen Bereiche	83
5.5.2. Erkennung der Störungsausfahrt	85
5.5.3. Bestimmung der Parameter	86
6. Untersuchungsmethodik zur Optimierung und Bewertung von SWIM	88
6.1. Gesamtkonzept	88
6.2. Simulationsumgebung PELOPS	90
6.2.1. Verkehrssimulator PELOPS	91
6.2.2. Erweiterungen von PELOPS	93
6.3. Aufbau der Szenariendatenbank	94
6.3.1. Streckenbeschreibung	95
6.3.2. Szenariendatenbank basierend auf realen Unfalldaten	95
6.3.3. Modellierung von Sonderszenarien	98
6.4. Gütekriterien	98
6.4.1. Detektionsrate	99
6.4.2. Fehlalarmrate	103
6.4.3. Optimierung und Bewertung von XFCD-Verfahren	105
6.5. Referenzverfahren für die Bewertung von XFCD-Verfahren	106
6.5.1. Datenbasis	106

6.5.2.	Vorgehensweise	106
6.6.	Emulationsumgebung	113
6.6.1.	Allgemeine Datenverarbeitung	113
6.6.2.	Durchlauf der XFCD-Verfahren	114
6.7.	Optimierung der Parameter von SWIM	115
6.7.1.	Struktur des Genetischen Algorithmus	115
6.7.2.	Ergebnis der Parameteroptimierung	117
7.	Bewertung des Verfahrens SWIM – Ergebnisse	120
7.1.	Bewertung des Verfahrens SWIM – Sensitivitätsanalyse	120
7.1.1.	Detektionsrate und Fehlalarmrate von SWIM	121
7.1.2.	Anwendungen im Bereich vorausschauender Regler	125
7.1.3.	Anwendungen im Bereich der Lokalen Gefahrenwarnung	126
7.1.4.	Anwendungen für routenwahlorientierte Verkehrsinformation	127
7.2.	Vergleich von SWIM mit existierenden XFCD-Verfahren	129
7.2.1.	Vergleich der Detektionsraten und Fehlalarmraten	129
7.2.2.	Anwendungen im Bereich vorausschauender Regler	132
7.2.3.	Anwendungen im Bereich der Lokalen Gefahrenwarnung	133
7.2.4.	Anwendungen für routenwahlorientierte Verkehrsinformation	134
7.2.5.	Auflösungsvermögen der XFCD-Verfahren	137
7.3.	Plausibilitätsprüfung mit Realdaten	138
7.3.1.	Vergleich mit stationären Daten	138
7.3.2.	Fehlermanagement	140
7.4.	Zusammenfassung der Ergebnisse	140
8.	Zusammenfassung und Ausblick	143
8.1.	Zusammenfassung und Schlussfolgerungen	143
8.2.	Ausblick	146
	Abbildungsverzeichnis	148
	Tabellenverzeichnis	152
A.	Abkürzungsverzeichnis	154
B.	Symbolverzeichnis	156
C.	Detektionsraten der XFCD-Verfahren	161
D.	Parameter XFCD-Verfahren	170

Zusammenfassung

Die Nachfrage nach örtlich und zeitlich fein aufgelösten Verkehrsinformationen steigt sowohl im privaten als auch im wirtschaftlichen Sektor an. Die vorliegende Dissertation beschäftigt sich mit der Erkennung von Verkehrsstörungen auf der Basis fahrzeuggenerierter Daten. Dabei liegt der Schwerpunkt auf einer zeitnahen und örtlich genauen Lokalisierung. Diese ist Voraussetzung für alle sicherheitskritischen Dienste wie etwa die Warnung vor einem Stauende hinter einer unübersichtlichen Kurve. Die Entwicklung, Optimierung und Evaluation des neu entwickelten Verfahrens wird mit Hilfe von Verkehrsflusssimulationen durchgeführt.

Zu Beginn der Arbeit wird ein Einblick in den Prozess der Entstehung von Verkehrsinformationen gegeben. In diesem Zusammenhang werden verschiedene Arten der Gewinnung von Verkehrsdaten beschrieben. Dabei wird insbesondere auf die Aufzeichnung hoch aufgelöster und detaillierter fahrzeuggenerierter Daten eingegangen. Diese erlauben eine streckenbezogene Datenerfassung im gesamten Straßennetz. Somit wird eine im Vergleich zu lokal messenden Erfassungssystemen feinere örtliche Informationsauflösung möglich.

Bisher stellen stationäre Erfassungssysteme die in der Praxis üblichen Datenquellen dar und sind die Basis für den Großteil der Arbeiten auf dem Gebiet der Störungserkennung. Dies berücksichtigend gibt diese Arbeit einen Überblick der Verfahren gegliedert nach Datenerfassung und Methodik.

Die Verwendung und Bewertung von Verfahren auf der Basis fahrzeuggenerierter Daten erfordert eine Definition des Begriffs Verkehrsstörung, welche eine exakte örtliche und zeitliche Lokalisierung von Störungen zulässt. Zu diesem Zweck wird eine Analyse mikroskopischer und makroskopischer Kenngrößen auf ihre Verwendbarkeit als Deskriptoren durchgeführt. Es zeigt sich, dass unter der Vielzahl makroskopischer Definitionen keine den für sicherheitskritische mikroskopische Anwendungen erforderlichen Detaillierungsgrad bietet. Aus diesem Grund wird eine eigene mikroskopische Definition eingeführt. Zur Quantifizierung der Güte von Verfahren zur Erkennung von Verkehrszuständen und Störungen wird eine Bewertungsmethodik entwickelt. Das Hauptkriterium für die Bewertung ist die Detektionsrate zur Erkennung einer vorhandenen Verkehrsstörung innerhalb eines Zeitintervalls und innerhalb eines örtlichen Versatzes. Hierbei werden sowohl Störungsein- als auch Störungsausfahrten betrachtet. In Kombination mit der Fehlalarmrate wird daraus die Güte des Verfahrens bestimmt.

Das in dieser Arbeit auf der Basis fahrzeuggenerierter Daten entwickelte Verfahren wird als **SWIM** bezeichnet – **Stoßwellenerkennung mittels Interventionsmodell**. Ziel von SWIM ist eine

hohe Güte der Erkennung hinsichtlich des entwickelten Bewertungsverfahrens, d.h. eine frühzeitige und örtlich genaue Erkennung von Störungseinfahrten und -ausfahrten auf Autobahnen. Während der Fahrt greift SWIM auf aktuelle Fahrzeugdaten, insbesondere die Geschwindigkeit und die Position, zu. Es werden keine Informationen aus dem Fahrzeugumfeld berücksichtigt. SWIM ordnet dann der Fahrt zu jeder Sekunde einen Zustand zu. Die Wechsel zwischen den Zuständen *frei* und *gestört* werden jeweils gemeldet.

SWIM hat eine modulare Struktur. Das Verfahren kann in zwei Funktionsblöcke unterteilt werden: den Bereich des Fehlermanagements, welches Datenfehler im Fahrtverlauf filtert und den Hauptteil der Erkennung von Verkehrsstörungen. Dieser setzt sich aus vier Modulen zusammen (siehe Abbildung 0.1).

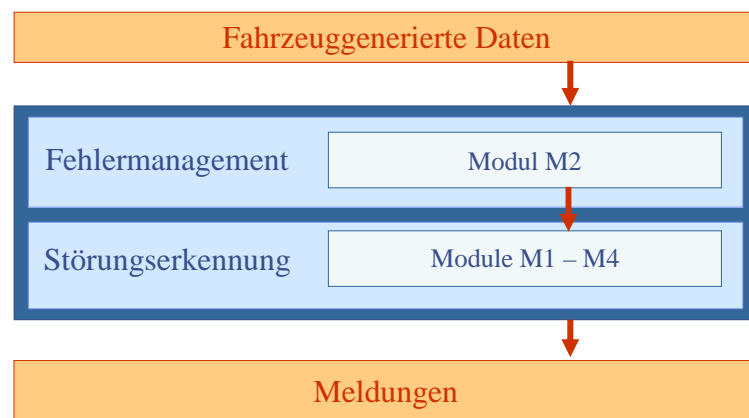


Abbildung 0.1.: Allgemeine Struktur von SWIM

Die einzelne Fahrt eines Fahrzeugs ist geprägt von stochastischem Rauschen. Um dies zu berücksichtigen, wird für die Erkennung ein stochastisches Zeitreihenmodell gewählt. Die Basis bildet die Modellierung der freien Fahrt eines Fahrzeugs mit Hilfe eines ARIMA-Modells. Eine Störung wird dann durch eine signifikante Abweichung vom normalen, d.h. freien Fahrtverlauf erkannt. Die Modellierung erfolgt dabei anhand zweier Interventionsmodelle, die Änderungen im Geschwindigkeitsverlauf und steile Geschwindigkeitsgefälle erkennen.

Die Entwicklung und Optimierung von SWIM wird mit Hilfe des mikroskopischen Verkehrsflussmodells PELOPS durchgeführt. Reale Versuchsfahrten dienen zur Plausibilisierung. Zur Optimierung der Parameterwerte von SWIM wird ein genetischer Algorithmus verwendet und eine Clusteranalyse durchgeführt.

Für die Bewertung von SWIM mit Hilfe von PELOPS wird ein Streckenabschnitt der A9 nachgebildet und eine Datenbank bestehend aus 104 Szenarien aufgebaut. Die Störungspositionen entsprechen realen Unfallstellen, für die verschiedene Störungsursachen modelliert werden. Basierend auf den eingeführten Gütekriterien wird ein Referenzverfahren entwickelt, mit dessen Hilfe die Qualität von auf fahrzeuggenerierten Daten basierenden Verfahren ermittelt werden

kann (siehe Abb. 0.2). Das Verfahren nutzt alle Simulationsdaten und wird offline durchgeführt.

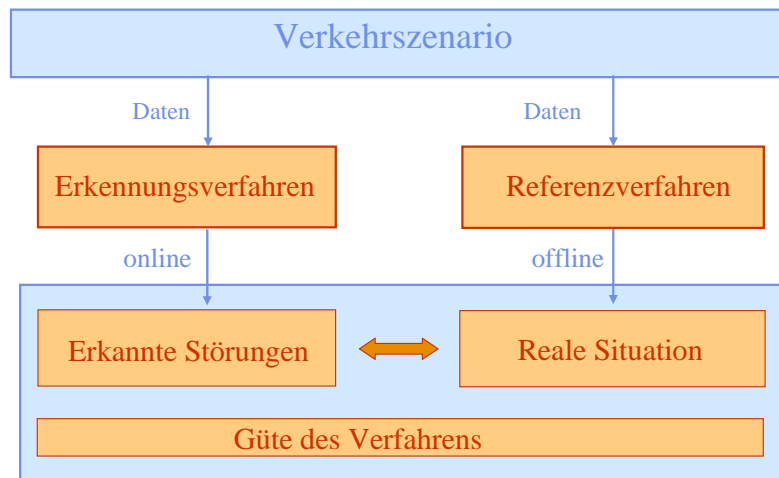


Abbildung 0.2.: Berechnung der Güte von Verfahren zur Erkennung von Verkehrsstörungen

Zur Evaluierung der Praxisrelevanz von SWIM wird das Verfahren in Hinblick auf Anforderungen aus den Anwendungsbereichen „Lokale Gefahrenwarnung“, „Auslegung vorausschauender Abstandsregler“ und „Routenwahl“ bewertet. Diese Verkehrsinformationsdienste stellen durch die stetige Weiterentwicklung in diesem Bereich immer strengere Anforderungen an die Qualität der Erkennung. Aus diesem Grund werden verschiedene zeitliche und örtliche Schwellenwerte analysiert und die Ergebnisse zusätzlich in Abhängigkeit der Störungsursache und Störungsausprägung betrachtet. Eine Sensitivitätsanalyse dient der Bestätigung der aus der Optimierung gewonnenen Parameterwerte. Im Weiteren erfolgt ein Vergleich von SWIM mit vier Verfahren basierend auf fahrzeuggenerierten Daten. Die Ergebnisse zeigen, dass SWIM eine Einfahrt schon bei kleinen zeitlichen Verzögerungen detektiert. Es werden 93% der Störungen innerhalb von 90s gemeldet. Sie haben einen örtlichen Versatz von unter 400 Metern. Die Erkennung der Ausfahrt erfolgt dagegen örtlich stärker versetzt, da SWIM einen Übergang erst erkennt, wenn das freie Geschwindigkeitsniveau wieder erreicht wird. Es zeigt sich, dass SWIM stark auf die Stärke des Übergangs von einem Verkehrszustand zum nächsten reagiert.

SWIM konnte bei allen sicherheitskritischen Anwendungen die höchsten Detektionsraten erzielen. So können bei einer geforderten Genauigkeit von 100 Metern, innerhalb derer sich die Störungseinfahrt bei Meldung der Störung befindet soll, knapp 63% der Einfahrten erkannt werden, während mit den Vergleichsverfahren innerhalb dieser Schwellenwerte zum Teil keine Erkennung möglich war.

Es zeigt sich, dass SWIM die Forderungen nach einer zeitnahen Erkennung und örtlich genauen Lokalisierung von Verkehrsstörungen erfüllt. Durch die damit verbundene frühzeitige Warnung nachfolgender Fahrer zeigt SWIM Potential zur Erhöhung der Verkehrssicherheit und Effizienz.

1. Einleitung

1.1. Kontext und Zielsetzung

Steigender Fahrzeugbestand und steigende Kilometerleistungen zeigen, dass der Wunsch nach Mobilität unverändert zunimmt [BAST 2005]. Das Zusammenwachsen innerhalb der europäischen Union und ihre Ausweitung führen zu einem wachsenden Wirtschaftsverkehr. Durch die zentrale geographische Lage und die Rolle als starker Handelspartner ist davon insbesondere Deutschland betroffen. Der Erhalt der Mobilität bei steigendem Verkehrsaufkommen stellt eine große Herausforderung an Gesellschaft und Technik dar.

Die Nachfrage im motorisierten Individualverkehr überschreitet zunehmend die zur Verfügung stehenden Kapazitäten des Straßennetzes. Die Folgen sind Staus und eine verringerte Verkehrssicherheit. Hinzu kommen Verspätungen, erhöhter Stress sowie zusätzliche Umweltbelastung. Die jährlich durch Staus anfallenden Kosten belaufen sich dabei auf mehrere Milliarden Euro (siehe u.a. [FRANK & SUMPFF 1997]). Ein unbegrenzter Ausbau des Straßennetzes ist jedoch nicht möglich, und aus ökologischen und ökonomischen Gründen oft nicht erwünscht. Stattdessen wird versucht, die vorhandene Infrastruktur mit geeigneten Maßnahmen optimal zu nutzen und den Verkehr effizient abzuwickeln. Systeme und Dienste, die dazu beitragen, den Verkehrsfluss mit geeigneten Informations- und Steuerungssystemen zu optimieren, werden unter dem Begriff Telematik zusammengefasst.

Im Bereich der individuellen Verkehrssysteme gewinnen Verkehrsinformationen und Zielführungssysteme zunehmend an Bedeutung. Durch eine gezielte Information und Unterstützung des Verkehrsteilnehmers soll der Verkehr entzerrt, das Straßennetz gleichmäßiger ausgelastet und Staus vermieden werden. Für den Verkehrsteilnehmer wird die aktuelle Verkehrslage kalkulierbarer; ein wichtiger Faktor in der heutigen Informationsgesellschaft, in der die Anzahl der Personen, die über mobile Geräte wie Mobilfunktelefone oder PDAs¹ jederzeit erreichbar sind, ansteigt. Auch Navigationssysteme werden zunehmend zu einem Massenprodukt. Dies alles führt dazu, dass immer mehr private Dienstleister versuchen, Dienste im Bereich Verkehrsinformation und Navigation anzubieten. Für Automobilhersteller, wie die BMW AG, ist die Bereitstellung von Verkehrsdiensten von besonderem Interesse. Abgesehen davon, dass es im Interesse der Firma liegt, dem Kunden die „Freude am Fahren“ zu erhalten, ist es wichtig, die Marke BMW als Premiumprodukt auch im Servicebereich zu platzieren und sich von anderen

¹Personal Digital Assistant

Diensteanbietern zu differenzieren. Den Stellenwert der Verkehrsinformation zeigt die Tatsache, dass sie auf der Liste der Kundenwünsche im Bereich der Telematikanwendungen nach der Notruf-Funktion, einer manuellen oder vollautomatischen Verständigung des Rettungsdiensts, an zweiter Stelle stehen [BMW AG 2003].

Bisher sind die angebotenen Verkehrsinformationen bei Weitem nicht ausreichend und genießen wenig Vertrauen. Die Meldungen sind häufig ungenau und zeitlich verzögert. Hierfür gibt es zahlreiche Gründe. So fehlt bis heute die erforderliche Datenbasis, die das gesamte Straßennetz abdeckt. Fest installierte stationäre Systeme bieten zwar lokal einen guten Einblick in die Verkehrssituation, sind jedoch nur punktuell und kaum außerhalb des Autobahnnetzes vorhanden. Dies macht die Verwendung weiterer Datenquellen notwendig. Ein Ansatz wurde in den letzten Jahren verstärkt weiterentwickelt - die Nutzung des Fahrzeugs als Datenlieferant. Als mobiler Sensor kann es streckenbezogene Daten im gesamten Straßennetz aufzeichnen. Technisch ist dieser Ansatz schon weit entwickelt. Gegenwärtig sind auf dem deutschen Fernstraßennetz bereits 40.000 Fahrzeuge als Datenlieferanten unterwegs [BREITENBERGER ET AL. 2004]. Diese senden in definierten Intervallen Geschwindigkeits- und Positionsdaten an eine Informationszentrale.

Neben der Datenerfassung selbst ist eine schnelle und zuverlässige Informationsgenerierung eine wichtige Voraussetzung für hochwertige Verkehrsinformationen. Damit diese korrekt und immer aktuell vorliegen, ist vor allem die automatische Erkennung der Übergänge zwischen den Verkehrszuständen von Bedeutung. Insbesondere die Erkennung von Verkehrsstörungen spielt hier eine große Rolle. Eine Vielzahl an Verfahren wurde bereits auf diesem Gebiet entwickelt; hauptsächlich für die Verwendung stationärer Daten. Trotzdem gibt es immer noch eine Vielzahl an Kritikpunkten bei ihrem praktischen Einsatz. Dazu zählen die Abhängigkeit der Erkennung von der Qualität der vorhandenen Daten, die mangelnde Übertragbarkeit der Verfahren auf andere Streckenabschnitte oder hohe Fehlalarmraten. Aussagen über die Qualität der Verfahren sind aufgrund unterschiedlicher Gütefunktionen und Testfelder kaum möglich. Durch die punktuelle Datenerfassung ergibt sich vor allem das Problem der zeitlich verzögerten Meldung und der örtlichen Ungenauigkeit. So kann eine Störung erst erkannt werden, wenn sie am Detektor gemessen wird.

Das Ziel der Arbeit ist es, ein Verfahren zu entwickeln, welches Störungen im Verkehrsablauf erkennt. Das Verfahren soll der Fahrt zu jedem Zeitpunkt einen Zustand zuordnen. Die Änderungen zwischen den Zuständen frei und gestaut bzw. gestaut und frei sollen sicher und zuverlässig erkannt und gemeldet werden. Zusätzlich wird gefordert, dass Verkehrsstörungen zeitnah und örtlich genau lokalisiert werden. Dies ist Voraussetzung für alle sicherheitskritischen Dienste, bei denen es auf eine schnelle Detektion und exakte Lokalisierung ankommt. Dazu gehören lokale Gefahrenwarnungen wie beispielsweise die Warnung vor einem Stauende hinter einer unübersichtlichen Kurve. Um die Störungen genau lokalisieren zu können, wird eine fahrzeug-

generierte Datenerfassung gewählt. Zudem findet die Ereigniserkennung im Fahrzeug statt, um das Meldeaufkommen und damit Sendekosten zu senken.

Um die Güte des entwickelten Verfahrens zu evaluieren, wird es zusammen mit vier weiteren, bei der BMW AG entwickelten, Verfahren untersucht und bewertet. Dies setzt jedoch eine geeignete Definition des Begriffs Verkehrsstörung für mikroskopische Verfahren voraus. In diesem Kontext bezeichnen mikroskopische Verfahren Verfahren, die fahrzeugautonom während der Fahrt arbeiten. Da es auf diesem Gebiet keine allgemein anerkannten Qualitätsaussagen gibt, werden eine mikroskopische Definition und mikroskopische Gütekriterien eingeführt. Ein Referenzverfahren, welches eine detaillierte Bestimmung der Güte der einzelnen Verfahren erlaubt, wurde entwickelt.

Die Bewertung erfolgt hinsichtlich unterschiedlicher Anwendungsbereiche. So werden die Verfahren auf Anforderungen im Bereich vorausschauender Regler, der Lokalen Gefahrenwarnung und der routenwahlorientierten Verkehrsinformation analysiert. Zeitkritische Dienste wie der der Lokalen Gefahrenwarnung sind speziell für den Außerortsbereich konzipiert, wo Geschwindigkeiten über 60 km/h zulässig sind [OBERT 2005]. Aus diesem Grund wird das Verfahren vorerst für Autobahnen kalibriert und getestet. Die Verwendung für das Sekundärnetz, wie etwa Bundes- oder Staatsstraßen, wird in dieser Arbeit nicht getestet, muss aber in einem nächsten Schritt erfolgen. Ebenso wenig wird der Schluss von der mikroskopischen Erkennung eines einzelnen Fahrzeugs zu einer makroskopischen Betrachtung gezogen, bei der eine Rekonstruktion und Prognose aufgrund der Erkennung mehrerer Fahrzeuge stattfindet. Auch dies muss in weiterführenden Arbeiten untersucht werden.

Das neue Verfahren wurde in einer Emulationsumgebung implementiert und in die zurzeit entwickelte Serienplattform des Fahrzeugs integriert.

1.2. Gewählter Ansatz

Durch die Komplexität und die zeitlich-räumliche Dynamik des Verkehrs ist eine Beschreibung des Verkehrsablaufs äußerst problematisch. Dieser wird durch eine Vielzahl an Faktoren beeinflusst, welche eine vollständige deterministische Modellierung nicht möglich machen.

Die Wahl eines Einzelfahrzeugs als Datenlieferant impliziert eine eindimensionale Abtastung des räumlich-zeitlichen Verkehrsfelds. Es stehen ausschließlich Daten zur Verfügung, die im Fahrzeug vorliegen und von den Datenbussen abgegriffen werden können. Es werden keine Informationen über das Fahrumfeld herangezogen. Die Fragestellung lautet somit, ob Rückschlüsse aus dem Fahrtverlauf auf die Verkehrssituation getroffen werden können. Erschwerend kommt hinzu, dass die Fahrt eines Einzelfahrzeugs für sich selbst genommen einen stochastischen Prozess darstellt, der stark durch die Fahrweise des Fahrers bedingt ist. Solche Einflussgrößen dürfen nicht fälschlicherweise als Störung detektiert werden. Es ist daher zielführend, ein Verfahren zu wählen, das der Stochastik des Verkehrs Rechnung trägt.

Das entwickelte Verfahren wird als **SWIM** bezeichnet – Stoßwellenerkennung mittels Interventionsmodell. Es eignet sich für eine zeitnahe und örtlich genaue Lokalisierung von Stoßwellen. SWIM ist modular aufgebaut. Die Hauptfunktion stellt die Störungserkennung dar. Den Kern bildet ein stochastisches Zeitreihenmodell (Transfer-ARIMA-Modell²), welches die internen Zusammenhänge des Fahrtablaufs modelliert und Rauschen berücksichtigt. Die Eignung von ARIMA-Modellen für die Modellierung linearer Zusammenhänge wurde unter anderem in BELZNER ET AL. (2003) gezeigt. Die Basis stellt ein ARIMA-Modell für den freien Fahrtverlauf dar. Eine Störung soll durch ihre Differenziertheit zum ungestörten Verkehr erkannt werden. Ihre Modellierung erfolgt anhand zweier Interventionsmodelle, die Unterschiede im Geschwindigkeitsniveau und starke Geschwindigkeitsabstiege erkennen. Neben den Zuständen frei und gestaut wird intern ein Bereich von instabilem Verkehr unterschieden. Dieser stellt den Übergang zwischen freiem und gestautem Verkehr dar.

Um Ausreißer, d.h. einzelne Datenfehler im Fahrtverlauf, zu erkennen, gibt es neben der Störungserkennung noch die Möglichkeit eines Fehlermanagements. Zu diesem Zweck wird ebenfalls das Interventionsmodell genutzt.

Die Entwicklung und Bewertung von SWIM erfolgt anhand von simulierten Daten, um alle möglichen Zustände zu testen. Auf der Grundlage der Simulationsdaten wird ein Referenzverfahren entwickelt, welches eine detaillierte Bewertung der mikroskopischen Verfahren ermöglicht. Dieses entspricht im Prinzip einem Ausstattungsgrad von 100% an Daten liefernden Fahrzeugen.

Die Bewertung von SWIM im Vergleich zu anderen mikroskopischen Verfahren zeigt die Eignung SWIMs für eine zeitnahe Erkennung mit geringem örtlichem Versatz.

1.3. Aufbau der Arbeit

Die Arbeit ist wie folgt aufgebaut. Kapitel 2 gibt einen Überblick über individuelle Verkehrsinformationen. Es wird der Prozess ausgehend von einem Verkehrsereignis über die Datenerfassung und Generierung einer Verkehrsmeldung bis zur Versendung an einen Empfänger dargestellt. Kapitel 3 beschäftigt sich mit dem Begriff der Verkehrsstörung. Zu Beginn werden die notwendigen verkehrstechnischen Grundlagen dargestellt. Hierfür werden verschiedene Kenngrößen eingeführt und ihre Nutzung als Deskriptoren für Verkehrsstörungen beschrieben. Ein Blick in die Literatur zeigt, dass es unterschiedliche makroskopische Definitionen von Verkehrsstörungen gibt. Ihre Verwendung für eine Untersuchung mikroskopischer Verfahren wird diskutiert und eine geeignete mikroskopische Definition vorgestellt. Kapitel 4 gibt im Anschluss einen Überblick über Verfahren zur Erkennung von Verkehrsstörungen. Die vier mikroskopischen Verfahren, die im Rahmen der Arbeit bewertet werden, werden hier detailliert vorgestellt. Die Entwicklung und Funktionsweise von SWIM wird im darauf folgenden

²engl.: autoregressive integrated moving-average

Kapitel 5 beschrieben. Im Anschluss werden in Kapitel 6 das verwendete Versuchsdesign und die Methodik der Untersuchung vorgestellt. Weiter erfolgt die Bestimmung der Parameter von SWIM anhand eines genetischen Algorithmus. Kapitel 7 beschreibt die Bewertung von SWIM und der zu vergleichenden mikroskopischen Verfahren. Schließlich werden die erarbeiteten Ergebnisse kurz zusammengefasst und ein Ausblick für weiterführende Untersuchungen gegeben.

2. Individuelle Verkehrsinformation und Datenerfassung

Dieses Kapitel gibt einen Überblick über die verschiedenen Formen der individuellen Verkehrsinformation. Es wird der Weg von einem Verkehrsereignis über die Datenerfassung bis zur Generierung einer Verkehrsinformation und ihre Verbreitung beschrieben. Insbesondere wird hier auf sog. „ontrip“-Informationen eingegangen. Weiter werden verschiedene Möglichkeiten der Datenerfassung aufgezeigt. Dabei steht die Erfassung von fahrzeuggenerierten Daten im Vordergrund.

2.1. Arten von Verkehrsinformationen

Vor dem Hintergrund des wachsenden Wirtschafts- und Freizeitverkehrs auf der einen und dem durch Staus entstehenden wirtschaftlichen Schaden auf der anderen Seite, ist die Nachfrage nach Dienstleistungen im Bereich Mobilität gestiegen und wird erwartungsgemäß noch stärker ansteigen. Dabei sind insbesondere aktuelle und auf den Kunden zugeschnittene Verkehrsinformationen von Interesse.

Die für Verkehrsmeldungen immer noch wichtigste und für jedermann zugängliche Quelle ist der Rundfunk. Jedoch senden die Rundfunkanstalten nur in bestimmten Intervallen, meist im Halbstunden- oder Stundentakt. In Stoßzeiten ist dann mit einer minutenlangen Liste von Meldungen zu rechnen, die dem Hörer Geduld und Konzentration abverlangen. Seit Herbst 1997 stehen dem deutschen Autofahrer aktuelle Verkehrsdaten über den digitalen Verkehrsfunkkanal RDS-TMC¹ zur Verfügung [VERKEHRSMINISTERIUM 2004]. Die Verkehrsmeldungen werden zu diesem Zweck digital kodiert und zusammen mit dem Hörfunk über UKW² gesendet. Sie können jederzeit abgerufen werden und stehen als Sprachausgabe oder in Textform auf der Anzeige des Navigationsgeräts zur Verfügung. Zusätzlich können sie als Symbole auf der Navigationskarte angezeigt werden.

Durch den europaweit einheitlichen Standard ist es zudem möglich, auch im Ausland Verkehrsmeldungen in Muttersprache zu erhalten. Aufgrund der beschränkten Übertragungskapazitäten kommt es jedoch zu Defiziten in der Genauigkeit der Meldungen. So ist die Datenmenge pro Meldung beschränkt. Des Weiteren können nur Ortsangaben gesendet werden, die auf einer sog. „Location Code“-Liste enthalten sind. Autobahnen sind auf der Liste als Abfolge der Anschlussstellen hinterlegt. Das hat zur Folge, dass eine Verkehrsstörung nur auf eine Strecke zwischen

¹Radio Daten System - Traffic Message Channel

²Ultrakurzwelle

zwei Anschlussstellen lokalisiert werden kann. Straßen des Sekundärnetzes, wie etwa Staatstraßen, sind nur bedingt in den Kodierungslisten hinterlegt [HÜBNER 2005].

Aufgrund der steigenden Nachfrage drängen verstärkt private Dienstleister auf den Markt mit dem Ziel, dem Anspruch des Kunden nach hochwertigen Verkehrsinformationen gerecht zu werden. Verkehrsinformationen der öffentlich-rechtlichen Anbieter wie Hörfunk und RDS-TMC werden aus den staatlich erhobenen GEZ³-Gebühren finanziert und stehen dem Nutzer ohne zusätzliche Kosten zur Verfügung. Für den Mehrwert der Dienste der privaten Betreiber muss der Kunde dagegen eine Gebühr bezahlen. Diese soll den dafür erforderlichen zusätzlichen Kostenaufwand decken. Je nach Dienst können die Informationen vor oder während der Fahrt auf Internetseiten, Mobiltelefone, PDAs oder das Navigationssystem übertragen werden.



Abbildung 2.1.: Navigationssystem mit BMW ASSIST

Neuere Navigationsgeräte können TMC-Meldungen oder Meldungen privater Anbieter, wie beispielsweise von VInfo+ im Dienstpaket ASSIST der BMW Group, bei der Routenplanung berücksichtigen (siehe Abb. 2.1). In diesem Fall kann eine „Last Exit Warnung“ ausgegeben werden, und der Fahrer wird kurz vor Erreichen der Störung dynamisch umgeleitet. Zukünftige Navigationssysteme sollen die Verkehrssituation nicht nur im Autobahnbereich, sondern im gesamten Straßennetz berücksichtigen. Erst dann wird es möglich sein, auch großräumig umzuleiten.

2.2. Meldekette

In diesem Abschnitt wird dargestellt, wie eine Verkehrsinformation schließlich den Verkehrsteilnehmer erreicht. Der Weg von der Erfassung der Verkehrsdaten bis hin zur Generierung der Meldung wird als Meldekette bezeichnet (siehe Abb. 2.2).

³Gebühreneinzugszentrale

Zentrales Element der Meldekette ist die Landesmeldestelle (LMS) der Polizei jedes Bundeslandes. Dort laufen sämtliche Daten der öffentlichen Hand zusammen, werden koordiniert und an die entsprechenden Adressaten weitergeleitet.

Stationäre Detektoren an lokalen Messquerschnitten der Autobahnen messen minütlich den Verkehrszustand und geben die Daten an die entsprechende Verkehrsrechnerzentrale (VRZ) weiter. Dort werden anhand der gemessenen Geschwindigkeiten und Verkehrsstärken automatisiert kodierte TMC-Meldungen erstellt und weiter an die LMS übermittelt (siehe Abb. 2.2). Auf der anderen Seite werden Informationen in den örtlichen Einsatzzentralen der Polizei manuell generiert. Quellen sind dabei Polizeistreifen, Hubschrauberflüge, die Notrufzentrale in Hamburg (GDV⁴) sowie Informationen der anderen Bundesländer und des Auslands. Hinzu kommen Meldungen von Radiosendern und privaten Staumelderorganisationen, die ihre Daten den Einsatzzentralen zur Verfügung stellen [ASSENMACHER 2005].

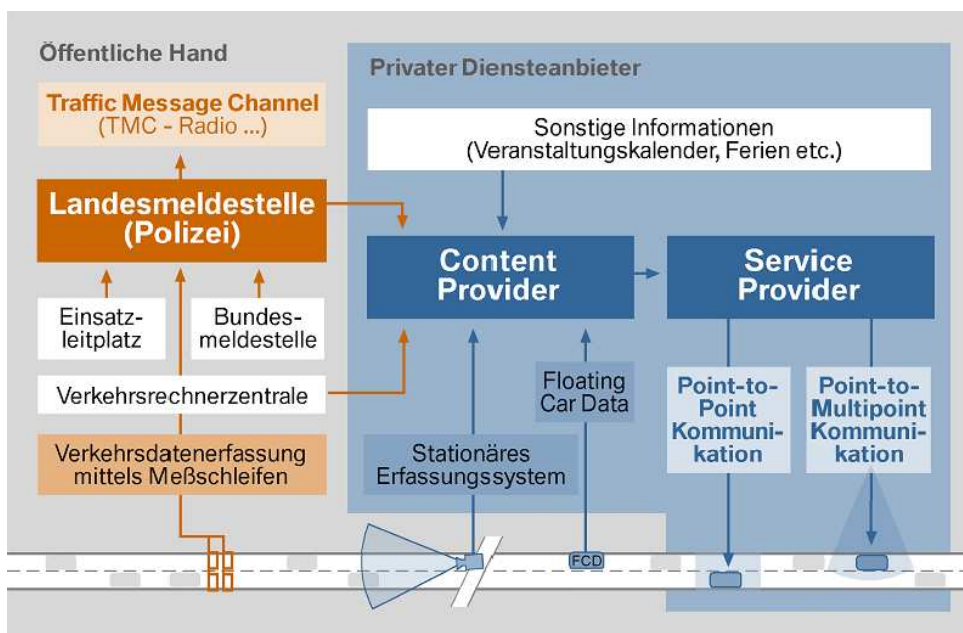


Abbildung 2.2.: Meldekette am Beispiel BMW ASSIST

Die Landesmeldestelle prüft die Daten auf Plausibilität und übermittelt sie an den ADAC⁵ und die Rundfunkanstalten. Von dort werden sie für die Mitglieder und die Hörer, zusammen mit eigenen erhobenen Meldungen, über Internet, Service-Telefon, SMS⁶, Hörfunk und RDS-TMC bereit gestellt.

Der öffentlichen Hand gegenüber stehen die privaten Diensteanbieter. Auf der rechten Seite von Abbildung 2.2 ist als Beispiel der Dienst von BMW ASSIST aufgezeigt. Der sog. Content Pro-

⁴Gesamtverband der Deutschen Versicherungswirtschaft e.V.

⁵Allgemeiner Deutscher Automobilclub

⁶Short Message Service

vider, die DDG⁷, sammelt Daten aus unterschiedlichen Datenquellen. Zum einen sind dies die Daten der öffentlichen Hand. Zusätzlich betreibt die DDG ein eigenes Stationäres Erfassungssystem (SES), das Messdaten per Mobilfunk an die Zentrale sendet. Dazu kommen etwa 40.000 Fahrzeuge, die ebenfalls gemessene Daten an die DDG senden. In der Zentrale werden die Verkehrsdaten zusammen mit weiteren Informationen wie zum Beispiel über Baustellen oder Großveranstaltungen sowie den Meldungen der LMS verarbeitet und fusioniert. Die so entstandene Verkehrsinformation wird kodiert und zum Service Provider weitergeleitet. Im Fall der BMW Group ist dies die T-Mobile Traffic. Sie ist für die Versendung der Verkehrsinformationen an den BMW-Kunden verantwortlich. Die Meldung kann auf zwei Arten an den Fahrer versendet werden: Über eine „Point-to-Point“-Verbindung werden die Informationen direkt über Mobilfunk an das Fahrzeug gesendet, wohingegen die „Point-to-Multipoint“-Verbindung die Daten über UKW verbreitet. Im Fahrzeug wird die Information dekodiert und kann schließlich im Navigationssystem verarbeitet und angezeigt werden.

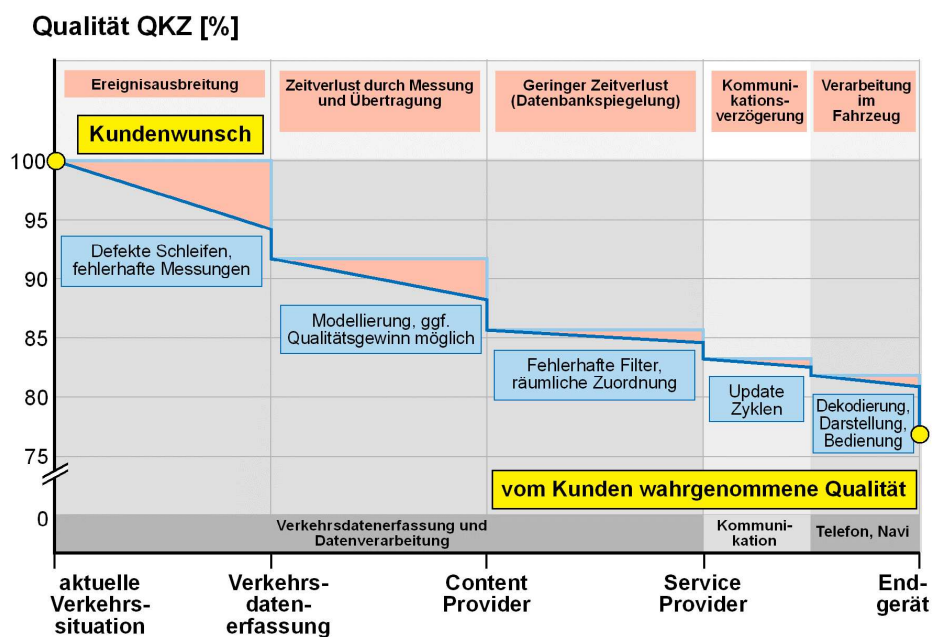


Abbildung 2.3.: Verlauf der Qualität innerhalb der Meldekette (Quelle: [BOGENBERGER 2003])

Der Kunde wird die zusätzlichen Gebühren allerdings nur dann zahlen, wenn er einen deutlichen Mehrwert zu den fast kostenfreien Verkehrsinformationen der öffentlich-rechtlichen Hand sieht. Der bisherige Stand ist jedoch, dass aufgrund der hohen Betreiberkosten und der langen Prozesskette noch nicht das Kosten-Nutzen-Verhältnis erreicht ist, das der Automobilhersteller seinen Kunden anbieten möchte und das den Kunden trotz zusätzlicher Gebühren über-

⁷Deutsche Gesellschaft für Verkehrsdaten mbH

zeugt. Die BMW Group ist daher um eine Verbesserung und Sicherung ihrer Verkehrsinformationsdienste bemüht. Dazu wurde ein Verfahren entwickelt, das die Qualität der Verkehrsinformationen nach objektiven Kriterien bewertet und das im Rahmen des Qualitätsmanagementsystems standardmäßig zum Einsatz kommt [BOGENBERGER 2003]. Die Schwierigkeit in der Bewertung von Verkehrsinformationsdiensten liegt dabei in der Beurteilung der Qualität von Informationen und insbesondere in der Rekonstruktion der realen Verkehrssituation. Aus diesem Grund wurden bisher hauptsächlich quantitative und technische Kenngrößen wie zum Beispiel die der zeitlichen und räumlichen Dienste-Versorgung des Kunden untersucht. Das neu entwickelte Verfahren betrachtet dagegen den Inhalt und die Aktualität der Informationen. Dazu wird die reale Verkehrslage anhand realer Messwerte rekonstruiert und zwei Qualitätskennziffern berechnet. Das Verfahren wurde im Rahmen umfassender Tests auf die einzelnen Glieder der Meldekette angewandt. Das Ergebnis ist in Abbildung 2.3 zu sehen. Dabei ist ein gemeinsamer Qualitätsindex für die einzelnen Schritte der Meldekette aufgezeichnet. Die linearen Anteile im Qualitätsverlauf geben den Verlust aufgrund zeitlicher Verzögerungen an. Die vertikalen Abstiege zeigen den Qualitätsverlust innerhalb des jeweiligen Prozesses. Es ist deutlich zu erkennen, dass die zeitliche Verzögerung einen Großteil des Qualitätsverlusts ausmacht. Dies wirkt sich auch in hohem Maße auf die Güte der Lokalisierung aus [BOGENBERGER & KATES 2002].

2.3. Erfassung von Verkehrsdaten

Im Folgenden werden verschiedene Arten der Datenerfassung vorgestellt. Der Schwerpunkt liegt dabei auf der Erfassung von fahrzeuggenerierten Daten. Diese können einen wichtigen Beitrag zu einer netzweiten Datenerfassung liefern.

2.3.1. Stationäre Datenerfassung

In der Praxis werden Verkehrsdaten fast ausschließlich auf der Basis stationärer Erfassungssysteme erzeugt. Dabei handelt es sich hauptsächlich um in der Straße fest installierte Induktivschleifen. Heute kommen auch optische, akustische oder Mikrowellen-Systeme zum Einsatz (siehe Abb. 2.4) [KELLER 2002B].

Diese Erfassungssysteme messen üblicherweise die Anzahl der Fahrzeuge, die über einen Messquerschnitt fahren und ihre Geschwindigkeit in den Formaten, die den Richtlinien der technischen Lieferbedingungen für Streckenstationen (TLS) entsprechen. In der Regel wird ein Aggregationsintervall von einer Minute verwendet und zwischen Pkw und Lkw unterschieden. Verkehrskenngrößen wie die Anzahl der Fahrzeuge zwischen den Messstationen und Reisezeiten können auf diese Weise nicht direkt bestimmt, sondern nur über Modelle näherungsweise berechnet werden.




Abbildung 2.4.: Stationäre Erfassungssysteme

Die gemessenen Daten werden in einer Zentrale ausgewertet und dienen als Datengrundlagen zur Verkehrsüberwachung oder für die Steuerung von Streckenbeeinflussungsanlagen. Zudem kann auf diese Art und Weise eine große Anzahl an Daten für verkehrliche Untersuchungen erzeugt werden. In der Realität sind diese erzeugten Daten jedoch häufig fehlerhaft, oder sie fehlen komplett. An Gefahrenstellen wie Baustellen liegen teilweise keine Messdaten vor, da mit den Bauarbeiten auch meistens die Datenübertragung gestört ist. Weitere Probleme entstehen durch hohe Unterhalts- und Reparaturkosten sowie durch Wetterabhängigkeiten.

Nichtsdestotrotz bieten stationäre Erfassungssysteme lokal einen guten Einblick über den Verlauf des Verkehrsgeschehens und eignen sich zur lokalen Verkehrsbeeinflussung. Für Verkehrsdienste, deren Anwendungen jedoch netzweite und streckenbezogene Daten benötigen, ist eine lokale Verkehrsdatenerfassung nicht ausreichend. Aus diesem Grund müssen zusätzliche Datenquellen herangezogen werden.

2.3.2. Fahrzeugseitige Datenerfassung

Die Idee, Fahrzeuge zur streckenbezogenen Aufzeichnung von Verkehrsdaten zu nutzen, entstand schon in den 50er Jahren [HUBER 2001]. In der Literatur sind diese Ansätze als Floating Cars, Probe Vehicles oder Moving Observers bekannt. In dieser Arbeit wird der Begriff Floating Car (FC) verwendet und die fahrzeugseitig erzeugten Daten als Floating Car Data (FCD) bezeichnet.

Technisch haben sich zwei Methoden durchgesetzt, die sich in der Art der Datenerfassung grundlegend unterscheiden und somit unterschiedliche Datengrundlagen und Anwendbarkeiten schaffen (siehe unten und Tabelle 2.1). Die technische Machbarkeit und die Eignung der beiden Methoden zur Erkennung der Verkehrslage wurden im Rahmen von Projekten und Feldtests gezeigt. HUBER gibt einen Überblick der dort erzielten Ergebnisse.

Bakengestützte Methode

Die Erhebung von Daten zwischen zwei am Fahrbahnrand angebrachten Baken wird als *bakengestützte Methode* bezeichnet. Diese Methode eignet sich gut für die direkte Aufzeichnung

von Reisezeiten. Es können jedoch auch andere fahrzeuggenerierte Daten ermittelt werden. In der Regel sendet das Fahrzeug die aufgezeichneten Daten an die Bake, von wo sie weiter an eine Verkehrszentrale übertragen werden. Das Fahrzeug empfängt auf umgekehrtem Weg Verkehrsinformationen oder Leitempfehlungen aus der Verkehrszentrale. Daneben können weitere Informationen, wie z.B. das digitale Straßennetz im System ALI-SCOUT, übertragen werden [LISB 1991]. Die Kommunikation selbst kann auch mobilfunkgestützt erfolgen.

Obwohl bei der Datenerfassung streckenbezogene Fahrzeugdaten aufgezeichnet werden, ist die eigentliche Aufzeichnung infrastrukturgestützt und hat somit auch mit deren Problemen der Datenaufzeichnung und -weitergabe sowie den infrastrukturbedingten Kosten zu kämpfen. Der größte Nachteil der bakengestützten Systeme ist die punktuelle Aufzeichnung. Es können ausschließlich zwischen den Baken Informationen generiert werden. Mit Nahbereichskommunikation können nur beim Passieren der Baken Informationen ausgetauscht werden. Dadurch ergibt sich eine zeitliche und örtliche Verzögerung der Meldungen. Für eine netzhafte Datenaufzeichnung müsste das gesamte Straßennetz mit Baken ausgestattet werden. Häufig wird eine vorhandene Infrastruktur (z.B. Mautstationen) um diese Methode der Datenerfassung erweitert.

	Mobilfunkgestützte Systeme	Bakengestützte Systeme
Datenver- sendung	-I.d.R. GSM -I.d.R. Ereignisbasiert	-I.d.R. Mikrowellentechnologie -I.d.R. Rohdaten oder Reisezeiten
Ort der Auf- zeichnung	Gesamtes Straßennetz	Punktuell
Feldtests	RHAPIT ⁸ , VERDI ⁹ , LoCoMoTiV ¹³	STORM ¹⁰ , LISB ¹¹ , DVB ¹²

⁸ Rhein-Main-Area Project for Integrated Traffic Management

⁹ Vehicle Related Dynamic Information

¹⁰ Stuttgart Transport Operation by Regional Management

¹¹ Leit- und Informationssystem Berlin

¹² Dynamisches Verkehrsleitsystem Berlin

¹³ Localisation and Communication in MoTiV

Tabelle 2.1.: Methoden der fahrzeuggenerierten Erfassung

Mobilfunkgestützte Methode

Bei der *mobilfunkgestützten* *Versendung* können Floating Cars ihre Daten im gesamten Straßennetz erheben und versenden - prinzipiell zu jeder Zeit an jedem Ort. Auf diese Weise kann eine netzweite Verkehrslageerkennung ermöglicht werden. Während stationäre Erfassungssysteme

nur an einer beschränkten Anzahl an Punkten im Verkehrsnetz, hauptsächlich auf Autobahnen, Daten liefern, können auf diese Art und Weise auch Aussagen über Nebenstraßen und Alternativrouten getroffen werden. Dies ist eine wichtige Voraussetzung für die Einführung eines erfolgreichen dynamischen Zielführungssystems, bei dem die aktuelle Verkehrslage berücksichtigt und darauf basierend eine Routenempfehlung generiert wird.

Als Kommunikationssystem wird in der Regel das GSM¹⁴-Netz genutzt. Die im Fahrzeug aufgezeichneten Daten können als Rohdaten, gefiltert zu Kenngrößen oder ereignisbasiert versendet werden. Um ereignisbasierte Meldungen zu versenden muss jedoch eine autonome Erkennung durch im Fahrzeug vorhandene Daten erfolgen. Das Hauptproblem der mobilfunkgestützten Systeme sind die hohen Kosten der Meldeversendung. Aus diesem Grund wird die Versendung der Daten in der Regel ereignisorientiert oder regelbasiert wie z.B. alle 5 Minuten realisiert.

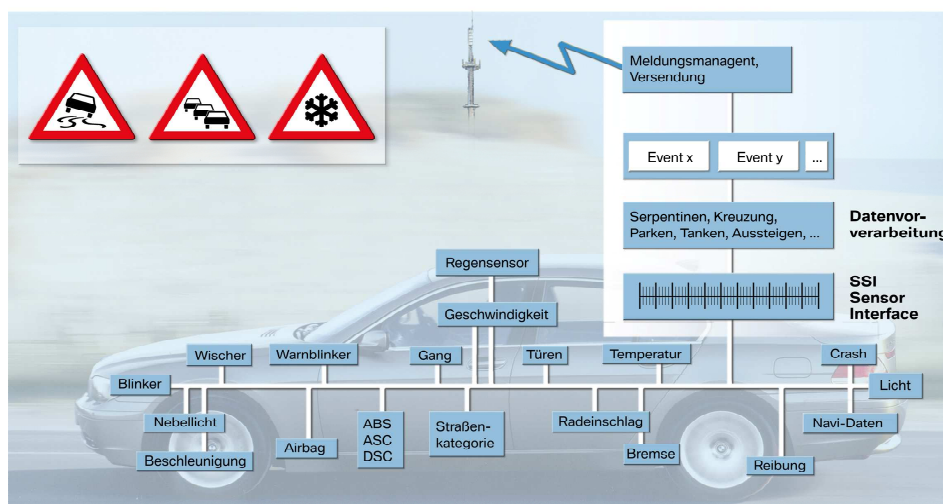


Abbildung 2.5.: Datengrundlage für XFCD

Nach BREITENBERGER ET AL. (2004) sind in Deutschland gegenwärtig etwa 40.000 Floating Cars unterwegs. Die Datenversendung erfolgt gemäß dem sog. GATS¹⁵-Protokoll nach definierten Transmissionskriterien. Dieses Protokoll wurde Mitte der 90er Jahre von den beiden ehemaligen Telematikunternehmen Passo (D1) und Tegarom (D2) als Spezifikation für die standardisierte Erfassung mobiler Verkehrsdaten und ihrer Informationsbereitstellung entworfen und ist heute EU-Norm. Mit Hilfe eines GPS¹⁶-Empfängers werden während der Fahrt sekundlich Geschwindigkeiten aufgezeichnet und zu mittleren Reisegeschwindigkeiten aggregiert. Bei Erfüllung eines der Transmissionskriterien, die auf zeitlichen, räumlichen oder auf definierten Ereignissen basieren, werden neben den Reisegeschwindigkeiten markante Wegpunkte in Form von sog. Perlenketten an die Zentrale geschickt [HUBER 2001].

¹⁴Global System for Mobile Communication

¹⁵Global Automotive Telematics Standard

¹⁶Global Positioning System

Die steigende Anzahl an elektronischen Komponenten ermöglicht das Abgreifen von zusätzlichen Daten von den Datenbussen. Mit ihnen kann die Qualität von Verfahren zur Verkehrszustandsschätzung verbessert werden. Weiter ermöglichen sie die Erweiterung des Spektrums an Verkehrsinformationsdiensten. In diesem Zusammenhang sind insbesondere Informationen über Wetter- und Straßenzustandsverhältnisse zu nennen. Diese Erweiterung wird als **Extended Floating Car Data** (XFCD) bezeichnet. Abbildung 2.5 veranschaulicht mögliche Datengrundlagen. Neben Daten wie Blinkerzustand oder Beschleunigungen können auch Informationen von fahrzeugseitiger Sensorik oder Fahrerassistenzsystemen in Betracht gezogen werden. Der große Vorteil der Datenerfassung mit XFCD ist, dass keine zusätzliche Sensorik in das Fahrzeug integriert werden muss. Alle Daten liegen bereits an den Fahrzeugbussen vor. Es genügt somit, das XFCD-Softwaremodul auf der Telematik-Plattform der Fahrzeuge zu implementieren. Dort können die Daten dann abgegriffen und über eine universelle Datenschnittstelle, dem sog. Standard Sensor Interface (SSI), in ein einheitliches Format konvertiert werden (siehe Abb. 2.5). Im XFCD-Modul sind die Algorithmen zur Datenverarbeitung und zur Erkennung implementiert. Im Gegensatz zu FCD wird nur bei Erkennung eines Ereignisses eine Meldung versendet. Zurzeit wird dies, analog zu FCD, über SMS realisiert. In Zukunft wird die Versendung über das GSM-Netz per GPRS¹⁷ erfolgen [BREITENBERGER ET AL. 2004].

2.3.3. Sonstige Arten der Datenerfassung

Der Vollständigkeit halber werden nachfolgend die Erfassung von Verkehrsdaten aus der Luft sowie die personen-basierte Datenerfassung besprochen.

Erfassung aus der Luft

Erste systematische Versuche der Datenaufzeichnung mit Flugzeugen wurden Anfang der 70er Jahre mit optischen Kameras unternommen, aber erst mit der Entwicklung hochauflösender Kameras und leistungsfähigerer Rechner wurde das Thema für die Verkehrsforschung wieder interessant. Allgemein lassen sich Aufnahmeverfahren mit optischen Kameras, Infrarotkameras und Radaraufnahmen unterscheiden [GRÜBER & HOLZ 2003].

Optische Aufnahmen sind im Vergleich preiswert und hochauflösend. SCHÜTTE ET AL. (1999) zeigten, dass auf diese Weise Fahrzeuggeschwindigkeiten sehr genau festgestellt werden können. Die Datenauswertung bzw. Fahrzeugerkennung erfolgt jedoch überwiegend manuell und ist wetter- und lichtabhängig. Das Verfahren ist somit aufwendig und noch nicht für Onlineverkehrslageinformationen geeignet. Dasselbe gilt für *Aufnahmen mit Infrarotkameras*. Die zu erfassenden Gebiete müssen in geringen Höhen (600 – 1000m) häufig durchflogen werden, da die Auflösung gering ist und es nicht möglich ist, Aufnahmen durch eine Wolkendecke zu machen.

¹⁷General Packet Radio Service

Diese Datenerfassung ist lediglich für bestimmte einzelne Aufnahmetermine (z.B. Großveranstaltungen) und zyklische Analysezwecke geeignet. Die einzige wetterunabhängige Methode ist die der *Radaraufnahme*. Mit ihr ist es zudem möglich, die Geschwindigkeit einzelner Fahrzeuge direkt zu erfassen.

Eine weitere Möglichkeit, die bisher nur in allerersten Probeaufnahmen durchgeführt wurde ist die Nutzung satellitengestützter Radarsysteme. Dabei muss jedoch die zeitliche Abhängigkeit der Aufnahmen von der Umlaufbahn des Satelliten in Kauf genommen werden [GRÜBER & HOLZ 2003].

Personen-basierte Datenerfassung

Letztendlich gibt es noch die Möglichkeit, *personen-basierte* Informationen auszuwerten. Die Erfassung erfolgt in Sprach- oder Textform, meist in Form von Telefonanrufen. Ein Beispiel hierfür ist die Generierung von Meldungen in den Einsatzzentralen der Polizei. Informationsquellen sind hierfür Polizeistreifen, Notruf, GDV, Rundfunksender sowie private Staumelderorganisationen. Die wichtigsten Staumelderorganisationen in Bayern stellen die Staumelder des ADAC¹⁸, die Bayern3ver von Bayern 3¹⁹ und der Verkehrsmelderclub von Antenne Bayern²⁰ dar. In der Telefonzentrale des ADAC werden die Anrufe der ADAC Staumelder und der Bayern3ver entgegengenommen. Antenne Bayern unterhält dagegen einen eigenen Telefondienst [ASSENMACHER 2005]. Ein Risiko stellt dabei die beim Fahren unerlaubte Nutzung der Mobiltelefone dar, die die Wahrscheinlichkeit von Zweitunfällen durch Unaufmerksamkeit erhöht.

Ein weiteres Beispiel für personen-basierte Daten ist die Videoüberwachung in einer Verkehrsleitzentrale, in der ein Mitarbeiter das Verkehrsgeschehen am Bildschirm verfolgt und je nach Verkehrslage Maßnahmen zur Verkehrsbeeinflussung ergreift.

Seit einiger Zeit werden Anstrengungen unternommen, die hohe Verbreitung von Mobiltelefonen zur Datenerfassung zu nutzen. Diese Methode wird als *Floating Phone Data* bezeichnet. Sie kann zur Familie der FCD-Methoden gerechnet werden, da statt dem Fahrzeug die Bewegungen eines Mobiltelefons verfolgt werden. Diese Methode hat den Vorteil, dass es die Aufnahme von Gesamtreisezeiten ermöglicht. Oft macht die Autofahrt, insbesondere die Autobahnfahrt, nur einen kleinen Anteil des Gesamtweges aus. Dazu kommen Fahrten mit dem ÖPNV²¹, per Rad oder zu Fuß. Für viele Kunden ist die Angabe einer Tür-zu-Tür Reisezeit interessant. Schwierig ist jedoch die fehlende Unterscheidung des Transportmittels. So ist aus den Positionsdaten nicht ersichtlich, ob sich ein Fahrzeug mit Mobiltelefon in einem Stau be-

¹⁸etwa 100.000 registrierte Melder

¹⁹etwa 8.300 registrierte Melder

²⁰etwa 3.000 registrierte Melder

²¹Öffentliche Personennahverkehr

findet oder ob die langen Reisezeiten durch ein anderes Fortbewegungsmittel wie z.B. Fahrrad zustande kommen.

Die Positionsdaten des Mobiltelefons können mit GPS-fähigen Endgeräten oder durch die Betrachtung von Zellübergängen bestimmt werden. Bei der Betrachtung von Zellübergängen können, ohne zusätzliche Übertragungskosten, sofort hohe Ausstattungsraten erreicht werden. Um die Erreichbarkeit der Handynutzer zu gewährleisten, werden Zellwechsel dem Mobilfunkbetreiber in jedem Fall gemeldet. Allerdings ist die Genauigkeit der Positionsverfolgung in hohem Maße von der Größe der Zellen abhängig. Werden GPS-fähige Mobiltelefone mit einer Software zur Ermittlung von Reisezeiten ausgestattet, erfolgt die Versendung über SMS. Das führt analog zu FCD zu hohen Sendekosten [BREITENBERGER & HAUSCHILD 2004].

2.4. Fazit

Ziel ist es, Verkehrsinformationen zeitlich und örtlich so präzise wie möglich zu erzeugen. Verfahren auf der Basis stationärer Erfassungssysteme können sich nur auf punktuelle Messungen stützen und müssen den Verkehr zwischen den einzelnen Messstellen rekonstruieren. Verfahren, die Daten aus der Luft aufnehmen, zeigen momentane Messungen, die die räumliche Verteilung des Verkehrs darstellen. Onlinefähige Verfahren müssen in diesem Bereich noch entwickelt werden. Der Ansatz mit FCD bzw. XFCD bietet das Potential, Daten streckenbezogen und netzweit aufzuzeichnen. So können Daten auch an Orten, an denen keine stationäre Erfassung stattfindet, aufgezeichnet werden. Dies gilt insbesondere für das Straßennetz außerhalb von Autobahnen. Aber auch auf Autobahnen ist XFCD Erfolg versprechend. Als zusätzliche Datenquelle kann sie Verkehrsdaten zwischen den Messquerschnitten liefern. So ist es möglich, Verkehrsstörungen zeitlich und örtlich genauer zu erkennen. Eine genaue Lokalisierung ist bei sicherheitskritischen Anwendungen wie Gefahrenwarnungen von großer Bedeutung.

Als zusätzliche Datenquelle zu den stationären Verfahren liefern fahrzeuggenerierte Daten somit einen wesentlichen Beitrag, die Qualität der Verkehrsdienste zu verbessern. Diese bieten Automobilherstellern wie der BMW Group die Möglichkeit, dem Kunden einen Service anzubieten, der im Vergleich zu allgemein erhältlichen Informationen qualitativ hochwertiger ist und ihre Marke aufwertet. Zudem ist es eine Möglichkeit, sich von anderen Automobilherstellern im Produkt- und Serviceangebot abzusetzen. Die Qualität der Verkehrsinformationen ist allerdings davon abhängig, wie gut und vollständig die aktuelle und zukünftige Verkehrslage im gesamten Straßennetz abgebildet werden kann. Dazu bedarf es insbesondere einer ständigen Verbesserung und Weiterentwicklung der Verfahren, die auf Basis der Verkehrsdaten Verkehrsstörungen erkennen und eine Verkehrsinformation erzeugen. Da die Versendung von fahrzeuggenerierten Rohdaten mit hohen Kosten verbunden ist, ist es sinnvoll, eine Verarbeitung der Daten schon im Fahrzeug durchzuführen und nur im Falle eines Ereignisses zu senden.

3. Verkehrliche Grundlagen und Verkehrsstörungen

Das nachfolgende Kapitel führt grundlegende verkehrstechnische Größen ein und beschreibt die Dynamiken, die für die Behandlung verkehrlicher Fragestellungen relevant sind. Darauf aufbauend werden Beschreibungen und Definitionen von Verkehrsstörungen diskutiert. Eine Definition für die Evaluation von Verfahren zur Störungserkennung, die fahrzeugautonom während der Fahrt arbeiten, wird vorgestellt.

3.1. Verkehrsstörungen

Das in dieser Arbeit entwickelte Verfahren erkennt Verkehrsstörungen auf der Basis mikroskopischer Daten. Die Verfahren arbeiten fahrzeugautonom, das heißt, sie sind in einem Fahrzeug implementiert und führen dort eine Erkennung durch.

Allgemein treffen Erkennungsverfahren eine Aussage über den gegenwärtigen oder möglicherweise auch zukünftigen Verkehrszustand. Die Entwicklung und Kalibrierung eines Erkennungsalgorithmus ist stark davon abhängig, welche verkehrliche Anwendung und welche Definition von Verkehrsstörung zugrunde liegen.

3.1.1. Begriff der Verkehrsstörung

WIKIPEDIA (2006) bezeichnet **Störung**

Definition 3.1 *[Störung] als Abweichung eines Vorgangs von seinem festgelegten oder vorausberechneten Verlauf aufgrund einer unvorhergesehenen endogenen oder exogenen Einwirkung.*

Hierbei wird als Störung das beeinflusste System bezeichnet und nicht auf die Ursache eingegangen. Diese Definition wird auch auf den Begriff der Verkehrsstörung übertragen. Es ist möglich Verfahren zu entwickeln, die aus dem Verlauf der Störungen und ihren Folgen auf die Störungsursache schließen lassen. Die Schwierigkeit liegt dabei jedoch in der Abhängigkeit des Verkehrskontexts von den verkehrlichen Randbedingungen und dem Umfeld. So ist es möglich, dass das gleiche Ereignis, etwa eine Fahrzeugpanne, bei niedrigem Verkehrsaufkommen in der Nacht keine Störung auslöst, während es tagsüber im Berufsverkehr eine große Störung bewirkt.

Es kann kurzzeitige oder ständige bzw. langandauernde Störungsursachen geben. Zum Beispiel bedeutet eine Baustelle eine längerfristige Beeinflussung des Verkehrs. Spurverengungen sind ebenfalls ständige potentielle Störungsquellen.

Großräumige Störungen werden häufig von unvorhergesehenen Unfällen oder Pannen verursacht sowie durch hohes Verkehrsaufkommen, wie es beispielsweise beim Urlaubsverkehr der Fall ist. Solche Störungen, die erhebliche Auswirkungen auf den Verkehrsfluss haben, werden in der Regel als **Stau** bezeichnet. Einer Studie des ADAC zufolge sind die Hauptursachen von Staus auf deutschen Autobahnen zu 33% Unfälle, zu 31% Baustellen und zu 32% hohes Verkehrsaufkommen [INVENT-BÜRO 2002]. Weitere Einflussgrößen sind:

- Schlechte Witterungsbedingungen (Nebel, Regen, Eis),
- Hoher Lkw-Anteil an Steigungsstrecken,
- Überholende Lkws,
- Langsamer Kolonnenverkehr,
- Schwere Transportfahrzeuge,
- Straßengeometrie (Kurven und Steigungen),
- Fahrbahnverschmutzungen (Laub) und
- Heruntergefallene Teile von Fahrzeugen.

Schließlich gibt es noch die sogenannten „Staus aus dem Nichts“, die sich ohne erkennbare Ursache bilden. Ihre Existenz ist jedoch umstritten. Verkehrsforscher wie DAGANZO sind der Meinung, dass jeder Stau auf die Existenz von **Engpässen**, sog. Bottlenecks, zurückzuführen ist. Dabei wird ein Engpass als eine *Inhomogenität bezeichnet, die reproduzierbare externe Ursachen hat* [DAGANZO ET AL. 1999].

3.1.2. Beschreibung des Verkehrsablaufs

Der Verkehrsablauf wird zunächst aus der Vogelperspektive betrachtet. Verkehr ergibt sich durch die Bewegung von vielen Fahrzeugen, von denen jedes Fahrzeug i zielgerichtet von einem Punkt A_i zu einem Punkt B_i fährt. Wäre jedes dieser Fahrzeuge allein auf der Strecke, ließe sich seine Route deterministisch verfolgen. Mit zunehmender Fahrzeuganzahl beeinflussen sich die Fahrzeuge. Es kommt zu Wechselwirkungen, deren Ausmaß insbesondere auch von den beteiligten Fahrern abhängt.

Der Verkehrskontext ist jedoch nicht nur von der Fahrer- und Fahrzeugpopulation und den damit verbundenen Interaktionen abhängig. Neben den verkehrlichen Randbedingungen spielt das Umfeld eine große Rolle. Dazu gehören zum einen die Streckencharakteristiken, also geometrische Eigenschaften wie Krümmung, Anzahl der Spuren, Breite des Fahrstreifens, Knotenpunkte oder das Vorhandensein von Sicherheitsstreifen. Zum anderen beinhaltet das Umfeld die Wetter-

und Straßenverhältnisse. Insbesondere diese Daten und ihr funktionaler Einfluss sind in der Regel unbekannt.

Bei einer Verkehrsstörung führt nun ein Ereignis zu einem veränderten Verkehrsablauf. Um diesen zu beschreiben und im Sinne einer speziellen Anwendung zu definieren, ist es notwendig, den veränderten Verkehrsablauf zu abstrahieren und mit Hilfe geeigneter Deskriptoren darzustellen (siehe Abb. 3.1).




Abbildung 3.1.: Abstraktion des Verkehrsablaufs mit Hilfe von Deskriptoren

3.2. Verkehrliche Kenngrößen und Deskriptoren

Im Folgenden werden verschiedene Kenngrößen des Verkehrs vorgestellt, die für die Beschreibung von Verkehrsstörungen verwendet werden können. Dabei wird zwischen makroskopischen und mikroskopischen Deskriptoren unterschieden. Da der Schwerpunkt der Arbeit auf der Erkennung von Verkehrsstörungen auf Autobahnen liegt, werden innerstädtische Kenngrößen und Deskriptoren nur kurz angesprochen.

3.2.1. Mikroskopische Betrachtung

Für detaillierte Untersuchungen, die das Verhalten eines oder einiger einzelner Fahrzeuge betreffen, wird eine mikroskopische Betrachtung gewählt. Das Fahrzeug wird als Partikel angesehen und seine Bewegung im Orts-Zeit-Kontext untersucht. Typische mikroskopische Anwendungsbereiche sind das Fahrzeug-Folge-Verhalten, die Spurführung sowie die Wirkungsweise von Fahrerassistenzsystemen und Lichtsignalanlagen. Dabei ist es in der Regel ausreichend, einen kleinen Systemabschnitt zu betrachten, dessen Umfeld wie Lichtsignalanlagen oder Verkehrszeichen allerdings detailliert dargestellt werden muss.

Während früher das Fahrzeugverhalten und seine Dynamiken aufgrund der technischen Einschränkungen nur stark vereinfacht nachgebildet werden konnten, ist mit den vorhandenen Rechenleistungen heute ein hoher Detaillierungsgrad möglich.

Mikroskopische Kenngrößen

Eines der wichtigsten Merkmale bei der mikroskopischen Betrachtung ist die Darstellung des Fahrtverlaufs im Orts-Zeit-Diagramm (siehe Abb. 3.2 a). Die **Geschwindigkeit** ist dabei die zentrale Größe und stellt die Tangente an die Kurve dar.

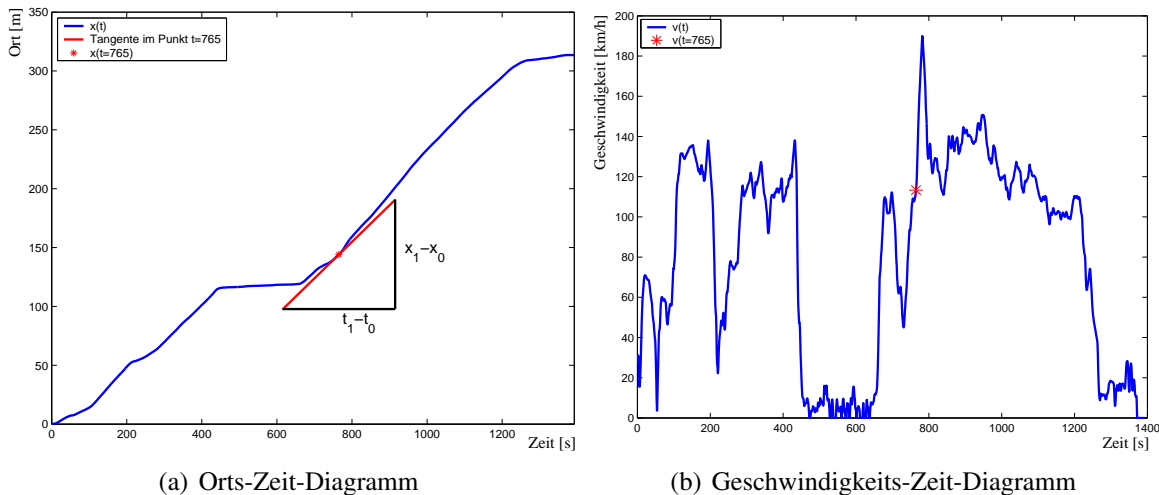


Abbildung 3.2.: Darstellung mikroskopischer Geschwindigkeiten

Prinzipiell können streckenbezogene Geschwindigkeitsdaten zu mittleren Geschwindigkeiten in Abhängigkeit der gefahrenen Zeit n_t oder der zurückgelegten Strecke n_x aggregiert werden. Zur Unterscheidung werden sie als Reisegeschwindigkeit v_R bzw. Streckengeschwindigkeit v_x bezeichnet.

$$v_R = \frac{1}{n_t} \cdot \sum_{i=1}^{n_t} v_i \quad \text{bzw.} \quad v_x = \frac{1}{n_x} \cdot \sum_{i=1}^{n_x} v_i, \quad n_t, n_x \in N$$

Dabei ist v_i die momentane Geschwindigkeit des Fahrzeugs zum Zeitpunkt i bzw. an Position i .

Die Wahl der Bezugsgröße ist abhängig von der gewählten Anwendung. In dieser Arbeit wird für die Geschwindigkeit immer die Bezugsgröße Zeit verwendet und als v bzw. für mittlere Geschwindigkeiten als \bar{v} geschrieben (siehe Abb. 3.2 b).

Bei der Aufzeichnung streckenbezogener Daten können mit Hilfe genauer Positionsmessungen auf einfache Weise **Reisezeiten** aufgezeichnet werden, indem die Zeit zwischen zwei beliebigen Referenzpunkten gemessen wird. Die Reisezeit stellt die wichtigste individuelle Kenngröße für den Fahrer dar. Allgemein bezeichnet die Reisezeit T_{RZ} die Zeit, die ein Fahrzeug benötigt, um eine Strecke $L_{Strecke}$ zu passieren.

$$T_{RZ} = \frac{L_{Strecke}}{\bar{v}}$$

Mit Hilfe von am Fahrzeug integrierter Sensorik, wie z.B. Radar, ist es möglich, Informationen über das Abstandsverhalten zum Vorderfahrzeug zu erhalten. **Fahrzeugabstände** spielen

eine große Rolle bei der Entwicklung und Auslegung von Fahrerassistenzsystemen sowie bei Fragestellungen im Bereich Verkehrssicherheit.

Neben den Messgrößen selbst bieten auch ihre statistischen Verteilungen und die Betrachtung von Häufigkeiten eine hohe Aussagekraft. Dazu zählt auch die Betrachtung von Streuungen wie zum Beispiel des **normierten Beschleunigungsrauschens**. Das Beschleunigungsrauschen σ_B gibt an, wie unruhig ein Fahrtverlauf ist, und kann nach LAPIERRE ET AL. (1987) als weiteres Kriterium für die Qualität des Verkehrsablaufs herangezogen werden.

$$\sigma_B = \sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (a_i - \bar{a})^2}$$

mit

n : Anzahl der betrachteten Zeitintervalle

a_i : Beschleunigung zum Zeitpunkt i

\bar{a} : Mittlere Beschleunigung

In der Regel wird das normierte Beschleunigungsrauschen Rn betrachtet, das auf der Basis der mittleren Reisegeschwindigkeit \bar{v} berechnet wird.

$$Rn = \frac{\sigma_B}{\bar{v}}$$

Im städtischen Verkehr ist der Verkehrsfluss durch Knotenpunkte und Lichtsignalanlagen geprägt. Hier spielen Kenngrößen wie **Verlustzeiten** oder **Anzahl der Halte** auf einer Strecke eine Rolle.

Mikroskopische Deskriptoren

Mikroskopische Deskriptoren versuchen eine Störung anhand einzelner Fahrzeuge zu beschreiben. Dabei ist zu beachten, dass die Fahrt eines Einzelfahrzeugs einen stochastischen Prozess darstellt. Abbildung 3.3 stellt die Einflüsse auf den Fahrer dar. Der Fahrer trifft auf der Basis der physikalischen Randbedingungen eine neue Entscheidung, die den weiteren Fahrtverlauf bestimmt. Die physikalischen Randbedingungen beinhalten den Verkehrskontext sowie den gegenwärtigen Fahrzeugzustand. Dabei sind Größen wie der Abstand zum Vorderfahrzeug oder die Wunschgeschwindigkeit von Bedeutung. Die Entscheidung des Fahrers ist abhängig von seiner Wahrnehmung und seiner Informationsverarbeitung. Emotionen (Aggressivität,...), situationsabhängige Variablen (Müdigkeit, Streß,...) oder Fehlverhalten (Ablenkungen,...) sind Störgrößen, die zu einem Abweichen vom normalen Fahrverhalten und zu einer unruhigen Fahrweise führen. Das hat zur Folge, dass es zu Schwankungen in der Geschwindigkeit und in den Beschleunigungen kommt, die ihre Ursache nicht im Verkehrskontext haben.

Ein Abweichen von einem „normalen“ Fahrtverlauf muss daher nicht unbedingt durch eine Störung verursacht sein. Es sollte immer klar sein, dass die Betrachtung eines Einzelfahrzeugs nur eine Stichprobe des Verkehrsablaufs darstellt. Mittelwerte und Standardabweichungen sind somit ein wichtiges Werkzeug, um statistische Aussagen zu treffen.

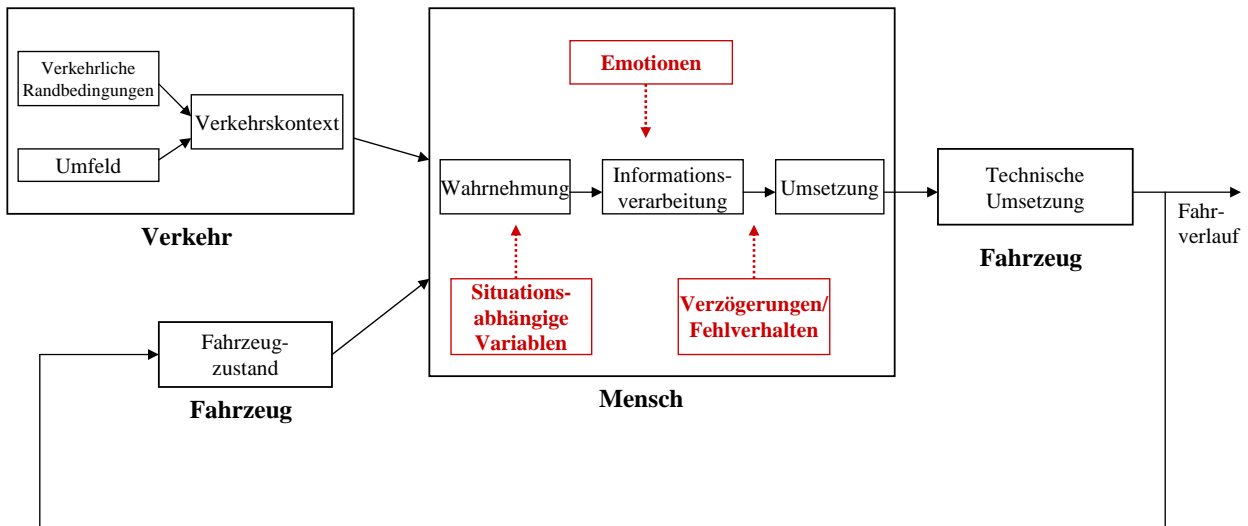


Abbildung 3.3.: Abhängigkeit des Fahrtverlaufs vom Fahrer

Verkehrszustände können durch folgende mikroskopische Deskriptoren beschrieben werden:

- Streckenbezogene Geschwindigkeit,
- Streckenbezogene Beschleunigung,
- Fahrzeugbezogene Reisezeiten,
- Normiertes Beschleunigungsrauschen,
- Fahrzeugabstände,
- Anzahl der Spurwechsel,
- Fahrzeugstillstände und
- Beschleunigungswechsel.

Freie Verkehrszustände zeichnen sich dadurch aus, dass sich alle Fahrer entsprechend ihrer Wunschgeschwindigkeit auf einer gewählten Spur fortbewegen können. Die Abstände zwischen den Fahrzeugen sind groß. Spurwechsel sind uneingeschränkt möglich. Die Fahrt hängt somit stark vom Fahrerverhalten ab (siehe ① in Abb. 3.4). Mit zunehmender Anzahl an Fahrzeugen auf der Strecke muss sich das individuelle Fahrerverhalten dem Kollektiv anpassen. Die Fahrer können ihre Geschwindigkeit nicht mehr frei wählen. Die Geschwindigkeiten auf den benachbarten Spuren passen sich an. Aufgrund des hohen Fahrzeugaufkommens ist ein großer Fahrzeugabstand nicht mehr möglich. Die Anzahl der Spurwechsel geht zurück.

Bei der Annäherung an eine Störung sinkt die Geschwindigkeit des einzelnen Fahrzeugs sowie des Kollektivs längs der Strecke ab. Die in die Störung einfahrenden Fahrzeuge bremsen stark ab (siehe ② in Abb. 3.4). Durch die Verzögerungen im Abbremsen und erneutem Beschleunigen stauen sich die nachkommenden Fahrzeuge auf. Je nach Stärke der Störung kann es zu einem Stillstand der Fahrzeuge kommen. Stop-and-Go Verkehr kann sich ausbilden (siehe ③ und ④ in Abb. 3.4). Erst nach dem Passieren des Engpasses beschleunigen die Fahrzeuge wieder (siehe ⑤ in Abb. 3.4).




Abbildung 3.4.: Mikroskopische Betrachtung des Geschwindigkeitsverlaufs

Durch die Messung von streckenbezogenen Geschwindigkeiten können diese Verläufe aufgezeichnet werden und erlauben auf diese Weise eine genaue Lokalisierung des Geschwindigkeitsabfalls bzw. des Geschwindigkeitsanstiegs und damit letztendlich des Engpasses. Neben den Geschwindigkeiten können auch streckenbezogene Beschleunigungen und Verteilungen Aussagen über den Verkehrszustand machen. Durch die geringen Geschwindigkeiten, das häufige Abbremsen und Beschleunigen kommt es zu einer Erhöhung der Reisezeiten auf dem Streckenabschnitt.

Im Sekundärnetz und im innerstädtischen Verkehr ist es unter Verwendung fahrzeuggenerierter Daten möglich, die Anzahl der Halte und den Wechsel in den Beschleunigungen zu untersuchen. Häufiges Anfahren und Abbremsen deutet dabei auf einen unruhigen Verkehrsfluss hin.

In Anlehnung an Verkehrsqualitätsstufen, wie sie auf der Basis makroskopischer Daten existieren (siehe Abschnitt 3.2.2), findet sich in BREITENBERGER (1997) eine Einteilung der Verkehrsqualität für mikroskopische Kenngrößen. Sie ist in Tabelle 3.1 dargestellt.

Verkehrsqualität		Beschreibung
a	Frei	Vollständig freier Verkehr
b	Leicht gebunden	Freier Verkehr
c	Gebunden	Steigendes Verkehrsaufkommen
d	Zähfließend	Starke Verkehrsbelastung
e	Stockend	Gestauter Verkehr
f	Stehend	Stehender Verkehr

Tabelle 3.1.: Mikroskopische Einteilung der Verkehrsqualitäten [BREITENBERGER 1997]

3.2.2. Makroskopische Betrachtung

Die makroskopische Abbildung betrachtet den Verkehr als Einheit und modelliert den Verkehrsfluss in Anlehnung an die Strömungsmechanik als fließendes Geschehen. Mathematisch werden die Zusammenhänge der Verkehrsgrößen durch partielle Differentialgleichungen dargestellt. Mit makroskopischen Modellen können verkehrstechnische Fragestellungen und Prognosen in großräumigen Bereichen schnell und einfach berechnet werden. Ein typisches Beispiel für makroskopische Betrachtungen ist die Untersuchung von Verkehrsbelastungen auf ausgewählten Streckenabschnitten oder die Verteilung der Verkehrsströme in einem Ballungsraum. Weitere Anwendungsbereiche sind Effizienzabschätzungen geplanter Verkehrsbeeinflussungsanlagen oder Straßenbaumaßnahmen sowie Verfahren zur Verkehrszustandsschätzung in Netzen.

Makroskopische Kenngrößen

Makroskopische Kenngrößen bezeichnen üblicherweise Messgrößen von lokalen Messquerschnitten. In der Vergangenheit standen an den Messstellen nur aggregierte Daten wie zum Beispiel zu Minuten gemittelte Werte zur Verfügung. Durch größere und billigere Speichermedien ist es heutzutage möglich, auch die ursprünglichen Einzelfahrzeugdaten zu erhalten. Um eine einheitliche Unterscheidung zwischen Mikroskopie und Makroskopie in den Kenngrößen und den Erkennungsverfahren zu verwenden, werden in dieser Arbeit mikroskopische und makroskopische Kenngrößen anhand der Art der Datenerfassung unterschieden.

Die typischen makroskopischen Kenngrößen bei der Beschreibung von Verkehrsflüssen bilden die Größen Geschwindigkeit v , Verkehrsstärke q und Verkehrsdichte k . Dabei gibt die **Verkehrsstärke** die Anzahl der Fahrzeuge an, die innerhalb eines festgelegten Zeitintervalls T einen Messquerschnitt MQ passieren (siehe Abb. 3.5). Sie wird in Fahrzeugen pro Zeiteinheit angegeben. Die maximale Verkehrsstärke, die an einem Messquerschnitt erreicht werden kann, wird als **Kapazität** bezeichnet. In der Praxis ist oft der **Auslastungsgrad** einer Strecke von Interesse. Dieser gibt das Verhältnis zwischen Verkehrsstärke und Kapazität an.

Bei der Analyse von **Geschwindigkeiten** ist es wichtig, zu unterscheiden, ob lokale oder momentane Geschwindigkeiten vorliegen. Während mittlere lokale Geschwindigkeiten \bar{v} an einem Messquerschnitt MQ über ein bestimmtes Zeitintervall T gemessen werden, gibt die mittlere momentane Geschwindigkeit \bar{v}_m die Geschwindigkeit zu einem bestimmten Zeitpunkt t über ein bestimmtes Ortsintervall $\Delta x = x_2 - x_1$ an (siehe Abb. 3.5).

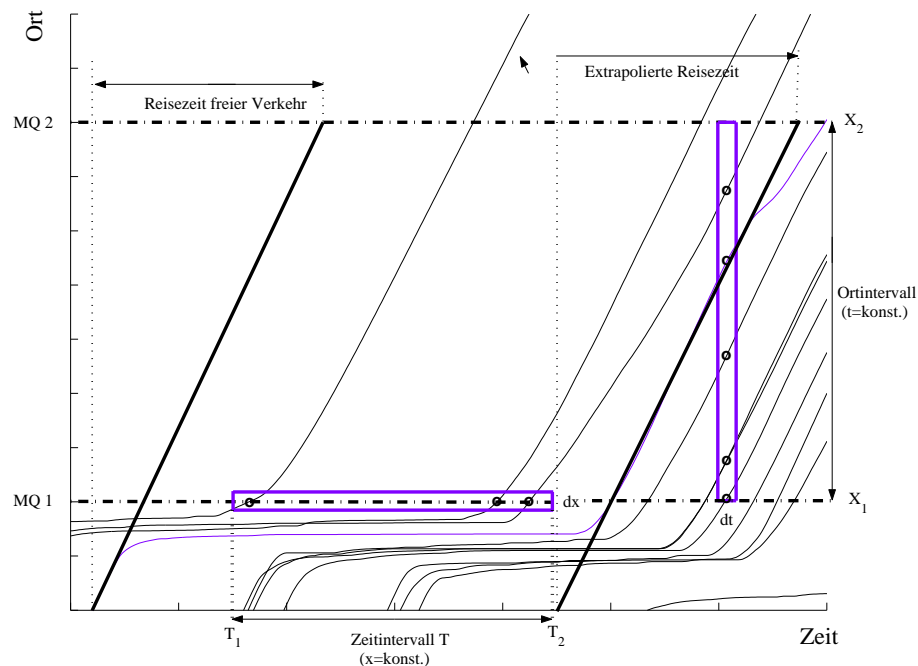


Abbildung 3.5.: Fahrzeugtrajektorien

Eine Schätzung von durchschnittlichen **Reisezeiten** zwischen zwei Messstationen ist über die Extrapolation der mittleren Geschwindigkeit an einem Messquerschnitt möglich. Neben der Reisezeit können auf diese Weise auch **Verlustzeiten** berechnet werden, indem die gegenwärtige Reisezeit mit der bei freiem Verkehr verglichen wird.

Die Verkehrsstärke und die Geschwindigkeit werden für makroskopische Kenngrößen lokal an einem Messquerschnitt gemessen. Im Gegensatz dazu ist die **Verkehrsdichte** k eine streckenbezogene Größe. Sie gibt die Anzahl der Fahrzeuge an, die sich innerhalb eines festgelegten Streckenabschnitts $\Delta x = x_2 - x_1$ befinden (siehe Abb. 3.5). Bildverarbeitende Verfahren ermöglichen eine direkte Messung. Weiter ist es auch möglich, die **Belastung** oder den **Belegungsgrad** eines Messquerschnitts zu ermitteln. Dieser gibt den prozentualen Zeitanteil an, für den eine Messstation mit Fahrzeugen besetzt ist, und stellt damit eine punktuelle „Mikro“-Dichte dar. Diese Messungen sind sowohl für einzelne Spuren als auch gemittelt über alle Spuren möglich.

Durch die Erhebung von Einzelfahrzeugdaten an Messquerschnitten können auf einfache Weise Abstände zwischen Fahrzeugen aufgezeichnet werden. Die Abstände können in zeitlichen Einheiten (**Zeitlücken**) gemessen oder räumlichen Einheiten (**Fahrzeugabständen**) berechnet

werden. In der Regel werden Bruttozeitlücken Δt_b analysiert, also die zeitliche Differenz, die zwischen dem Passieren zweier Fahrzeuge an einer Stelle auftritt. Der Fahrzeugabstand Δx_n misst den Abstand zwischen zwei Fahrzeugen (siehe Abb. 3.6). Fahrzeugabstände machen indirekt eine Aussage über die gegenwärtige Fahrzeugdichte k .

$$k = \frac{1}{\frac{1}{n} \cdot \sum_{i=1}^n \Delta x_{b,i}}$$

wobei

$n + 1$: Anzahl der Fahrzeuge innerhalb eines Abschnitts

$\Delta x_{b,i}$: Bruttoabstand zwischen Fahrzeug i und $i + 1$.




Abbildung 3.6.: Fahrzeugabstände

Aus den Nettozeitlücken Δt_n und den relativen Geschwindigkeitsunterschieden

$\Delta v = v_{Vorderfahrzeug} - v_{Folgefahrzeug}$ können **Auffahrzeiten** (t_{tc}^1 -Werte) berechnet werden.

$$t_{tc} = \frac{\Delta t_n \cdot v_{Vorderfahrzeug}}{\Delta v}, \quad \text{mit } v_{Vorderfahrzeug} \neq 0$$

Die Auffahrzeit berechnet sich aus dem Verhältnis des Nettoabstands zu der Geschwindigkeitsdifferenz zweier aufeinander folgender Fahrzeuge. Kleine, negative Auffahrzeiten weisen dabei auf gefährliche Situationen hin, bei denen sich ein Fahrzeug schnell seinem Vorderfahrzeug nähert.

Makroskopische Deskriptoren

Aussagen über den Verkehrszustand werden meist auf der Basis makroskopischer Verkehrsgrößen getroffen, die punktuell und in großen Mengen an den Messstationen vorliegen. Folgende makroskopische Kenngrößen bieten sich als Deskriptoren an:

- Geschwindigkeit,
- Verkehrsstärke,
- Belegungsgrad,

¹engl.: time to collision

- Verkehrsdichte,
- Extrapolierte Reisezeiten,
- Verlustzeiten,
- Auslastungsgrad,
- Zeitlücken,
- Auffahrzeiten,
- Umlaufzeiten und
- Warteschlangen.

Die Geschwindigkeit, die Verkehrsstärke und der Belegungsgrad stehen direkt am Messquerschnitt zur Verfügung und können dort lokal ausgewertet werden. Die Dichte wird in der Regel berechnet.

Bei einer Störung kommt es zu einer Ansammlung von Fahrzeugen, woraufhin sich die Dichte oder der Belegungsgrad stromaufwärts der Störung erhöht und stromabwärts abfällt. Dabei sinkt die Geschwindigkeit der in die Störung einfahrenden Fahrzeuge ab. Je nach Stärke der Störung kann es zu einem Stillstand der Fahrzeuge kommen. Erst nach dem Passieren der Störung beschleunigen die Fahrzeuge wieder auf ihre Wunschgeschwindigkeit. Durch das Aufeinandertreffen der Dichtewellen des freien und des gestauten Verkehrs bildet sich eine Stoßwelle. Fahren mehr Fahrzeuge in die Störung hinein als Fahrzeuge die Störung verlassen, breitet sich die Störung gegen die Fahrtrichtung aus. Durch Abbremsen und niedrige Geschwindigkeiten kommt es zu einer Erhöhung der Reisezeiten auf dem Streckenabschnitt. Eine Differenz zwischen der gegenwärtig erhöhten Reisezeit und der Reisezeit bei freiem Verkehr deutet auf eine Verkehrsstörung zwischen zwei Abschnitten hin und führt zu Verlustzeiten.

Wenn die Verkehrsstärke in der Nähe des maximalen Flusses liegt, befindet sich der Verkehr im metastabilen Bereich. Es herrscht ein hoher Auslastungsgrad. Zu beachten ist, dass die Kapazität eine dynamische Größe ist, die unter anderem in Abhängigkeit von unterschiedlichen Fahrweisen der Verkehrsteilnehmer oder Witterungsbedingungen variiert. Eine Angabe der Kapazität kann aus diesem Grund nur ein Näherungswert sein. Es ist jedoch möglich, die Kapazität über lange Messreihen empirisch anzunähern. Sie wird als **maximale empirische Kapazität** bezeichnet.

Weiter können auch Zusammenhänge zwischen den einzelnen Messgrößen untersucht und Korrelationen berechnet werden. Die kumulierten Verteilungen der Zeitlücken und der Auffahrzeiten können Hinweise auf gefährliche Situationen geben und sind wichtige Größen bei Untersuchungen zur Verkehrssicherheit.

Im innerstädtischen Verkehr bzw. im Sekundärnetz kommt es durch Lichtsignalanlagen zu einem Verkehrsverlauf, der dem bei gestörten Verkehr ähnlich ist, ohne dass dieser störungsbe-

dingt sein muss. Dies gilt insbesondere für die Geschwindigkeit. Aus diesem Grund müssen im Stadtbereich andere Kriterien gefunden werden, die diesem Sachverhalt Rechnung tragen. Eine Möglichkeit ist das Überschreiten von Umlaufzeiten an einer Lichtsignalanlage. Wenn Fahrzeuge nicht nach dem ersten Umlauf über eine Kreuzung fahren können, kann dies ein Hinweis für eine Störung sein. Es kommt zu einer Warteschlange, die sich auch bei einer Grünzeit nicht auflöst. Ihre Länge und Dauer kann berechnet werden.

Um die Qualität des Verkehrsablaufs auf unterschiedlichen Straßenanlagen zu beurteilen, wurde im Januar 2002 das Handbuch zur Bemessung von Straßenverkehrsanlagen (HBS) durch die FORSCHUNGSGESELLSCHAFT FÜR STRASSEN- UND VERKEHRSWESEN EV (FGSV) (2001) eingeführt. Es ist vergleichbar mit dem Highway Capacity Manual (HCM) in den USA und ist wie dieses ein Richtlinienwerk für die Ermittlung der Qualität des Verkehrsablaufs. Dabei werden die Zusammenhänge zwischen Verkehrsbelastung und Verkehrsqualität sowie die Kapazität in Abhängigkeit von verkehrlichen, entwurfsabhängigen und umfeldbezogenen Randbedingungen dargestellt.

Qualität	Beschreibung
A	Freier Verkehr
B	Nahezu freier Verkehrsfluss, keine direkte Beeinträchtigung
C	Spürbare Beeinträchtigung
D	Deutliche Beeinträchtigung des Verkehrsablaufs
E	Starke Behinderungen zwischen den Verkehrsteilnehmern, Verkehr an Kapazitätsgrenze
F	Stau

Tabelle 3.2.: Stufen der Verkehrsqualität [FGSV 2001]

Anhand empirisch ermittelter Kennfelder kann die Qualität je nach Straßenkategorie durch unterschiedliche Indikatoren ermittelt werden. Das Maß für die Verkehrsqualität auf Bundesautobahnen ist der Auslastungsgrad der Strecke. In Anlehnung an das HCM wird eine Einteilung in sechs Qualitätsstufen A-F vorgenommen (siehe Tabelle 3.2).

3.3. Definition von Verkehrsstörungen

In diesem Abschnitt wird zuerst eine Darstellung der, in der Literatur existierenden, makroskopischen Definitionen gegeben. Darauf basierend wird die Eignung makroskopischer und mikroskopischer Deskriptoren für eine detaillierte Untersuchung mikroskopischer Verfahren diskutiert. Schließlich wird eine, für die Untersuchung geeignete Definition vorgestellt.

3.3.1. Makroskopische Definitionen

Der Blick in die Literatur zeigt, dass die Arbeiten im Bereich der Verkehrsflusstheorie schwerpunktmäßig aus den USA, aus Deutschland und aus Japan stammen. In allen drei Industrienationen stellen die Folgen von Verkehrsstörungen seit Jahren ein großes wirtschaftliches und finanzielles Problem dar. Die Länder zeichnen sich durch eine hohe Mobilität und eine dichte Besiedlung in den Ballungsräumen aus. Dazu kommt die Ausweitung der Ballungsräume, da immer mehr Bewohner in die umliegenden Randgebiete ziehen. Das hat zur Folge, dass weite Wege zurückgelegt werden müssen. In den USA treten Staus seit einiger Zeit verstärkt in den Vorstädten auf, wohingegen früher vor allem die städtischen Schnell- und Landstraßen gestaut waren [OZBAY & KACHROO 1999].

In Japan kommen neben den oben aufgeführten Gründen noch topographische Gegebenheiten zum Tragen. Die große Anzahl an Tunnel und Senken hat eine hohe Anzahl an infrastrukturbedingten Engpässen zur Folge, die den ohnehin dichten Verkehr verstärkt zum Erliegen bringen [OKAMURA ET AL. 2000].

Verkehrsstärke-Dichte-Beziehungen

Ein wichtiges Instrument bei der Beurteilung von Verkehrszuständen ist die Betrachtung der Beziehungen zwischen den makroskopischen Verkehrsgrößen q , k und v . Insbesondere die Verkehrsstärke allein erlaubt keine eindeutige Darstellung des Verkehrszustands. So kann eine niedrige Verkehrsstärke sowohl durch eine geringe Anzahl von Fahrzeugen, als auch durch das langsame Fortbewegen der Fahrzeuge in einem Stau zustande kommen.

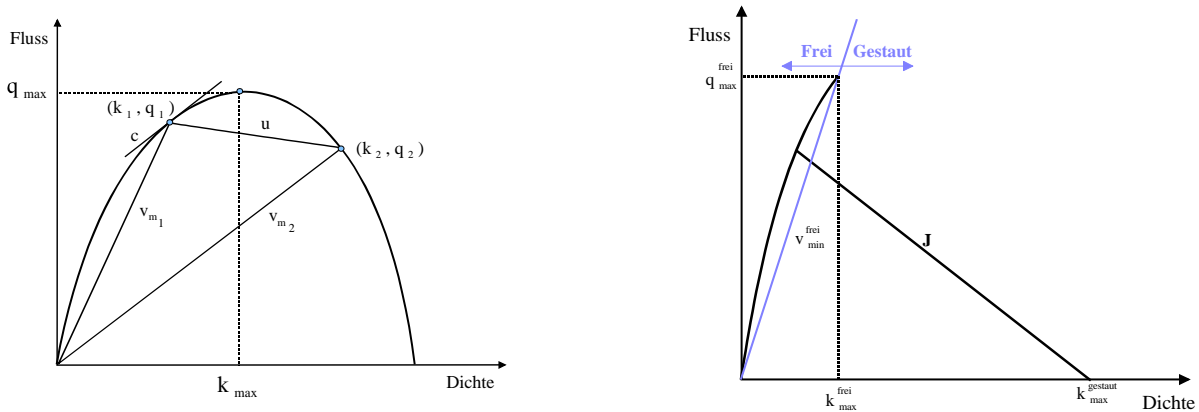
Fundamentaldiagramm Für die Beschreibung des Verkehrszustands werden in der Regel die Verkehrsstärke und die Verkehrsdichte verwendet und ihr Verhältnis in einem q - k -Diagramm, dem sog. **Fundamentaldiagramm**, betrachtet (siehe Abb. 3.7).

Eines der ersten Modelle dieser Art ist das Fundamentaldiagramm nach GREENSHIELDS (1935), das eine parabolische Form aufweist (siehe Abb. 3.7(a)). Die Verkehrsstärke steigt demnach mit zunehmender Dichte bis zu einem Punkt maximaler Stärke an und fällt dann ab. Das Maximum (k_{max}, q_{max}) stellt die Trennung zwischen den Bereichen des freien und des gestauten Verkehrs dar. Die Steigung $\frac{q}{k}$ gibt die momentane Geschwindigkeit für den Zustand (k, q) an. Obwohl sich das Modell von GREENSHIELDS bei der Verwendung heutiger Daten als inkonsistent erweist und nicht mit aktuellen gemessenen Geschwindigkeiten und Verkehrsstärken übereinstimmt, dominierte es für Jahrzehnte das Gebiet der Verkehrsforschung [GARTNER ET AL. 1992].

Im Laufe der letzten Jahrzehnte entstand eine Reihe von Modellen mit dem Ziel, die verkehrlichen Zusammenhänge exakter zu beschreiben (siehe u.a. [GAZIS ET AL. 1961], [EDIE 1961],

[MAY & KELLER 1968]). KOSHI ET AL. führten 1983 die inverse Lambda-Form der Fluss-Dichte-Beziehung ein [KIM 2002]. Dabei *zeichnen sich gestaute Verkehrszustände* dadurch aus, dass ihre mittlere Fahrzeuggeschwindigkeit geringer ist, als das Minimum der möglichen mittleren Geschwindigkeit v_{min}^{frei} im freien Verkehr (siehe Abb. 3.7(b)). Weiter tritt eine Synchronisation der Geschwindigkeiten über alle Autobahnspuren auf [KOSHI ET AL. 1983].

Die Formen der q-k-Diagramme unterscheiden sich insbesondere im Bereich des gestauten Verkehrs, in dem die Messdaten weit gestreut sind. Im Bereich des freien Verkehrs weisen sie weitestgehend übereinstimmend eine quasi-lineare Form auf. Nach BANKS (2002) gibt es drei dominierende Formen des Fundamentaldiagramms: die inverse U-Form, die inverse V-Form und die inverse Lambda-Form. Außerdem können Größen wie die Position der Messstation, die Aufzeichnungsrate, das zeitliche Aggregationsintervall, die Wahl der betrachteten Spur sowie Schätzfehler bei der Dichteberechnung Auswirkungen auf die Form der Fluss-Dichte-Beziehung haben.



(a) Fundamentaldiagramm nach GREENSHIELDS

(b) Unterscheidung zwischen freiem und gestautem Verkehr [KOSHI ET AL. 1983]

Abbildung 3.7.: Verkehrsstärke-Dichte-Beziehungen

Kinematische Wellen und Stoßwellen Unter der Voraussetzung der Differenzierbarkeit der Größen Verkehrsstärke, Verkehrsdichte und mittlere Geschwindigkeit nach Ort und Zeit, kann die Bewegung der einzelnen Fahrzeuge als kontinuierliches Fließgeschehen angesehen und als kinematische Wellen modelliert werden. Dabei gilt Flusserhalt, d.h. die Fahrzeuge, die in einen Streckenabschnitt ohne Rampen hineinfahren, entsprechen denen, die aus dem Abschnitt ausfahren zuzüglich derer, die sich noch innerhalb des betrachteten Abschnitts befinden.

Die Kontinuitätsgleichung modelliert diesen Sachverhalt:

$$\frac{\partial k}{\partial t} + \frac{\partial q}{\partial x} = 0 \quad (3.1)$$

Die Ersten, die sich mit dieser Theorie befassten und sie auf den Verkehr anwendeten, waren LIDTHILL UND WHITHAM (1955), gefolgt von RICHARDS (1956). Die Theorie ist seitdem unter dem Namen der „Theorie der kinematischen Wellen“ bekannt.

Die Kontinuitätsgleichung 3.1 kann ohne weitere Zusatzbedingungen oder Annahmen nicht gelöst werden. Sinnvoll ist es, die bekannten Zusammenhänge der Verkehrsvariablen ($q = k \cdot v_m$) vorauszusetzen und anzunehmen, dass der Fluss q an jedem Punkt der Straße eine Funktion der Dichte k ist. Die Tangente an die Zustandskurve im Fundamentaldiagramm

$$c = \frac{dq(k)}{dk}$$

wird hierbei als Ausbreitungsgeschwindigkeit der kinematischen Wellen bezeichnet. Die Dichtewelle pflanzt sich demnach mit der Geschwindigkeit c fort. Trifft jedoch ein Strom niedriger Verkehrsdichte auf einen mit hoher Verkehrsdichte kommt es zu Diskontinuitäten. Die Wellen unterschiedlicher Dichte stoßen aufeinander, und es entsteht eine Stoßwelle u [KELLER 2002A].

$$u = \frac{q_2 - q_1}{k_2 - k_1}$$

wobei

$q_1 - u \cdot k_1$: Rate der in die Stoßwelle einfahrenden Autos

$q_2 - u \cdot k_2$: Rate der aus der Stoßwelle ausfahrenden Autos

Je nach Vorzeichen pflanzt sich die Stoßwelle stromauf- oder stromabwärts fort. Diese Tatsache zeigt sich im Fundamentaldiagramm an der Steigung der Sekante u (siehe Abb. 3.7(a)).

Eine Störung ist demnach an den Übergangsgebieten von Stoßwellen umgeben und kann nach BUSCH folgendermaßen definiert werden:

Definition 3.2 [Störung] Eine **Störung** ist definiert als der Übergang eines Verkehrsstroms von einem Zustand in einen anderen. Der Übergang ist örtlich und zeitlich von einer Stoßwelle beschränkt [BUSCH 1991].

Die Entstehung von Stoßwellen sind Folgen von Singularitäten in den Lösungen der Kontinuitätsgleichung erster Ordnung. Da auf diese Weise Formen wie die der spontanen Staubbildung nicht nachgebildet werden können, werden häufig auch Modelle höherer Ordnung betrachtet.

Unterscheidung mehrerer Verkehrsphasen

Wie in Abschnitt 3.3.1 gezeigt wurde, existieren vielfältige Formen des Fundamentaldiagramms. Heute wird der gestaute Bereich üblicherweise durch ein zweidimensionales Gebiet dargestellt (siehe Abb. 3.8). Weiter unterteilen aktuelle Verkehrsfluss-Theorien das Fundamentaldiagramm

nicht nur in die Phasen frei und gestaut, sondern versuchen, den Verkehr speziell in der Übergangsregion zwischen freiem und gestautem Verkehr sowie das zweidimensionale Gebiet des gestauten Verkehrs detaillierter zu beschreiben.

3-Phasen-Theorie nach KERNER Basierend auf empirischen Daten entwickelte KERNER die sog. 3-Phasen-Theorie, die die zeitlich-örtlichen Dynamiken des Verkehrsflusses erklären soll. Dabei unterscheidet er den freien und gestauten Verkehr entsprechend der Definition von KOSHI ET AL. Der freie Verkehr wird im Fundamentaldiagramm als Kurve mit positiver Steigung dargestellt. Den gestauten Verkehr unterscheidet KERNER weiter in synchronisierten Verkehr und sogenannte breite, sich bewegende Staus. Im gestauten Verkehr gilt, dass die Geschwindigkeit der Fahrzeuge absinkt und eine Fortbewegung mit Wunschgeschwindigkeit nicht mehr möglich ist. Im Unterschied zum freien Verkehr ist die Wahrscheinlichkeit von überholenden Fahrzeugen im synchronisierten Verkehr gering. Die stromabwärtige Staufront des synchronisierten Verkehrs bleibt in der Regel ortsfest. Wenn sie sich stromaufwärts bewegt, ist ihre Geschwindigkeit jedoch, im Gegensatz zu breiten Staus, nicht konstant.

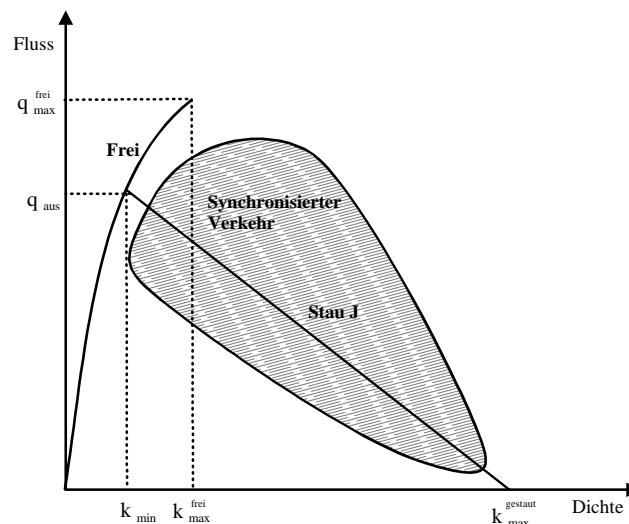


Abbildung 3.8.: Verkehrsphasen in der Fluss-Dichte-Ebene [KERNER 2004]

Ein **breiter, sich bewegendes Stau** ist nach KERNER (2002) eine, sich stromaufwärts bewegende Struktur, die von zwei Staufronten beschränkt ist, an denen sich die Geschwindigkeit scharf ändert. Dabei ist die Distanz zwischen den Fronten weit größer als die Breite der Staufront. Die Geschwindigkeiten im Stau sind sehr gering, die Dichte sehr hoch.

Ein breiter, sich bewegendes Stau pflanzt sich ungehindert durch alle anderen Verkehrszustände fort. Er hat charakteristische Parameter, die weder zeitabhängig sind, noch von mathematischen Anfangsbedingungen abhängen. Sie sind allein abhängig von der Verkehrszusammensetzung, also dem Anteil an Lkw's, sowie den Umfeldbedingungen wie Infrastruktur, Wetter und anderen Straßenbedingungen [KERNER 2002]. Der wichtigste charakteristische Parameter ist die

Geschwindigkeit der stromabwärtigen Staufront, die während der Staufortpflanzung konstant ist. Sie wird in der Fluss-Dichte-Ebene durch die charakteristische Linie J dargestellt (siehe Abb. 3.8).

Der Anfangs- und Endzeitpunkt eines breiten Staus können durch Messung der Geschwindigkeiten an einem Detektor erkannt werden. Die Bestimmung der genauen Zeitpunkte muss nach KERNER (1999) mit Verfahren zur Störungserkennung, wie z.B. Schwellenwerten, durchgeführt werden.

Basierend auf den oben dargestellten Annahmen der 3-Phasen-Theorie entwickelte KERNER (2004) das Verfahren ASDA²-FOTO³ zur Erkennung und Verfolgung der aktuellen Verkehrslage (siehe Abb. 3.9). Dazu identifiziert das Verfahren FOTO zunächst den Verkehrszustand aufgrund lokaler Messungen am Detektor. Danach führen die Verfahren ASDA und FOTO eine Erkennung der Grenzen der breiten, sich bewegenden Staus bzw. des synchronisierten Verkehrs an den Detektoren durch und verfolgen diese zeitlich und räumlich weiter.

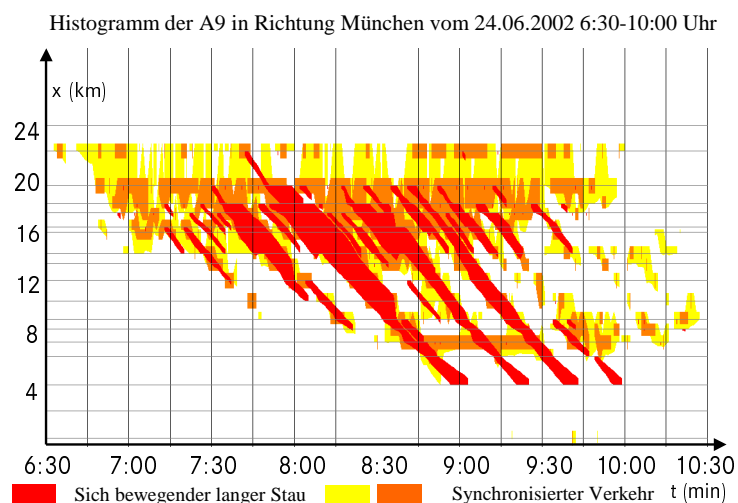


Abbildung 3.9.: Das Verfahren ASDA-FOTO (Quelle: [KERNER ET AL. 2003])

Phasendiagramm nach HELBING Anhand von Simulationen leiteten HELBING & TREIBER. (2002) ein Phasendiagramm mit einer Einteilung in verschiedene Verkehrszustände her. Unter der Annahme, dass Staus auf Autobahnen vorwiegend an Rampen oder anderen Engpässen auftreten, wurde die Entwicklung an einem Autobahnabschnitt mit einer Auffahrtsrampe durchgeführt. Die so getroffenen Aussagen wurden von HELBING & TREIBER auf andere Arten von Engpässen verallgemeinert und anhand von empirischen Untersuchungen bestätigt [SCHÖNHOF & HELBING 2004].

²Automatische Staudynamikanalyse

³Forecasting of Traffic Objects

Wenn die Anzahl der Fahrzeuge auf einer Strecke die dynamische Kapazität q_{max} übersteigt, sich der Verkehr also im instabilen Bereich befindet, lösen schon kleinste Störungen einen Stau aus. Das kommt bei einem zu hohem Verkehrsaufkommen, wie es typischerweise im Berufsverkehr der Fall ist, vor. Meistens liegen die Gründe jedoch in Engpässen, die auf ein externes Ereignis zurückzuführen sind, und die Kapazität der Strecke einschränken.




Abbildung 3.10.: Verkehrsstärken am Engpass

Nach SCHÖNHOF & HELBING (2004) können auch Schwankungen unterhalb der Kapazitätsgrenze q_{max} des betrachteten Autobahnabschnitts einen Stau auslösen. Dies ist dann der Fall, wenn sich der Verkehr im metastabilen Bereich befindet. Während im absolut stabilen Bereich alle Störungen gedämpft werden, verschwinden im metastabilen Bereich nur kleine Unruhen. Aufgrund der Verzögerungen in den Reaktions- und Beschleunigungszeiten entsteht ein kurzzeitiger Stau, bei dem sich die Verkehrsstärke auf q_{aus} reduziert. Wenn dann die Verkehrsstärke in den Stau den Fluss q_{aus} übersteigt, entwickelt sich die Unruhe zu einem größeren Stau und breitet sich stromaufwärts aus (siehe Abb.3.10).

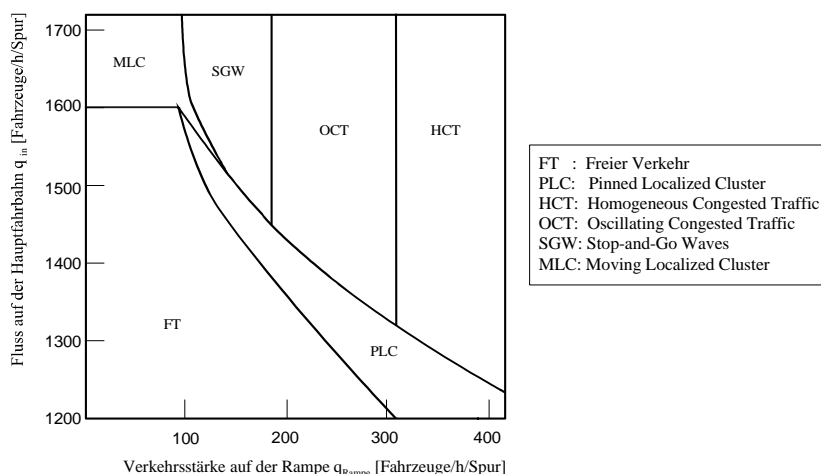


Abbildung 3.11.: Phasendiagramm [HELBING & TREIBER 2002]

HELBING & TREIBER charakterisieren Staus anhand ihrer Verkehrsstärken. Das Phasendiagramm wird daher in Abhängigkeit von der Verkehrsstärke q_{in} auf der Hauptfahrbahn und der

Verkehrsstärke q_{Rampe} einer Auffahrtsrampe angegeben. Es unterscheidet zwischen freiem und fünf gestauten Verkehrszuständen (siehe Abb. 3.11).

Phasendiagramm nach KIM KIM (2002) interpretiert das Fundamentaldiagramm als Zustandsdiagramm, in dem die Größen Verkehrsstärke q und Verkehrsdichte k als Zeitreihen an einem Messquerschnitt aufgefasst werden. Er unterscheidet ebenfalls 6 Verkehrszustände (siehe Abb. 3.12).

KIM unterscheidet die Zustände des freien Verkehrs (frei und teilgebunden) und des gestauten Verkehrs (synchronisiert, stockend und gestaut) anhand zweier Kriterien. *Im freien Verkehr sind im Vergleich zum Stau die Mittelwerte $\mu_{\Delta t_b}$ und die Standardabweichungen $\sigma_{\Delta t_b}$ der Zeitlücken groß. Zudem gleichen sich im Stau die Geschwindigkeiten auf den benachbarten Spuren an.* Für quantitative Aussagen über die Unterschiede in den Zeitlücken wird das Produkt $\mu_{\Delta t_b} \cdot \sigma_{\Delta t_b}$ verwendet.

Für die Identifikation der Übergänge zwischen den gestauten Zuständen werden die makroskopischen Größen Geschwindigkeit und Verkehrsstärke verwendet. Nach KIM ändern sich die Verkehrszustände während eines kurzen Zeitintervalls. Um diesen zu bestimmen, bildet er aus den beiden Größen einen Indikator, der die Verhältnisse zwischen der letzten und der vorausgegangenen 5 Minuten berücksichtigt.

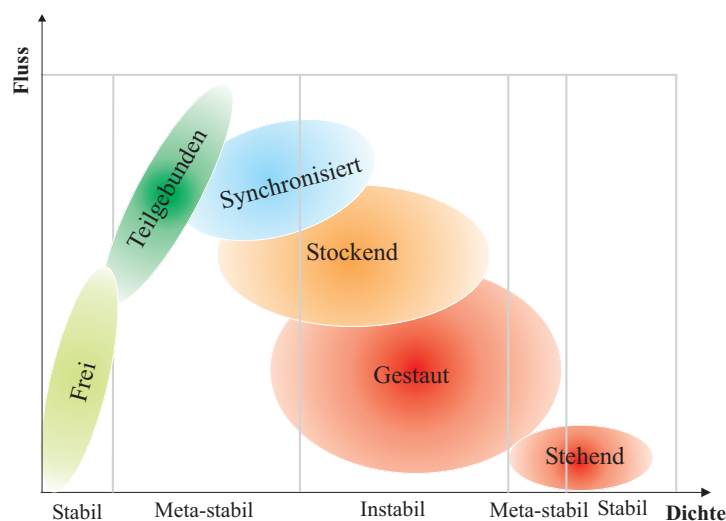


Abbildung 3.12.: Zustandsdiagramm des Verkehrs [KIM & KELLER 2001]

Kumulative Kurven

Aufgrund der Schwächen der Lighthill-Whitham-Theorie schlug NEWELL vor, kumulative Kurven für die Analyse des Verkehrs zu verwenden. Diese Methode wurde von der Gruppe der Forscher um NEWELL, DAGANZO, CASSIDY und MAY weiterentwickelt.

In Abbildung 3.13 links sind zwei kumulative Kurven dargestellt. Jede Kurve $N(x_j, t)$ ($j = 1, 2$) gibt die Anzahl der Fahrzeuge an, die, einem bestimmten Referenzfahrzeug folgend, bis zum Zeitpunkt t den Ort x_j passieren. Der vertikale Abstand $N(x_1, t) - N(x_2, t)$ gibt dabei die Anzahl der Fahrzeuge an, die sich zwischen x_1 und x_2 befinden, der horizontale Abstand zeigt die Reisezeit des Fahrzeugs i für den Abschnitt $x_2 - x_1$ an [NEWELL 1993].

Die Verwendung kumulativer Kurven hat den Vorteil, dass sie den Massenerhalt garantiert:

$$k(x, t) = \frac{-\partial N(x, t)}{\partial x} \quad \text{und} \quad q(x, t) = \frac{\partial N(x, t)}{\partial t} \quad (3.2)$$

Die Anwendung der Kontinuitätsgleichung 3.1 führt mit den Gleichungen 3.2 dann auf:

$$\frac{\partial^2 N(x, t)}{\partial x \partial t} = \frac{\partial^2 N(x, t)}{\partial t \partial x}$$

Nach DAGANZO ET AL. (1999) pflanzen sich *Unruhen im freien Verkehr stromabwärts fort während sie sich im gestauten Verkehr stromaufwärts bewegen*. Die Stellen, an denen sich Staus, bei DAGANZO ET AL. als Warteschlangen bezeichnet, bilden und Instabilitäten entstehen, werden als Engpässe bezeichnet. Stoßwellen kennzeichnen den Übergang zwischen freiem und gestautem Verkehr. Die Ankunft einer Stoßwelle an einem Messquerschnitt ist im kumulativen Diagramm durch ein Auseinanderdivergieren der übereinander gelegten Kurven zu erkennen (siehe Abb. 3.13 rechts).

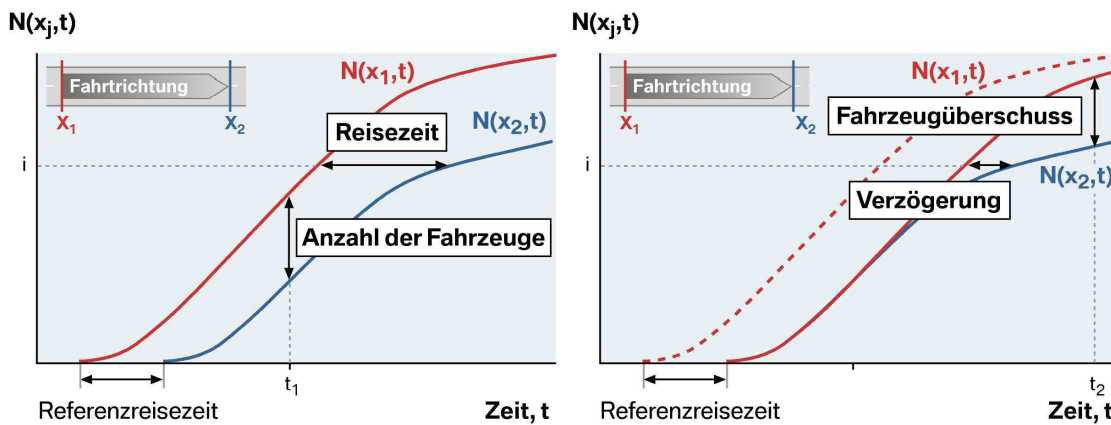


Abbildung 3.13.: Kumulierte Fahrzeugankunftszeiten
(Quelle: [BOGENBERGER ET AL. 2006A])

3.3.2. Diskussion der Deskriptoren

Neben unterschiedlichen Formen von Fundamentaldiagrammen und kumulativen Kurven existieren eine Vielzahl weiterer Definitionen (siehe u.a. [DOUGHERTY ET AL. 1998], [ZHANG ET AL. 1994], [ZOU & LEVINSON 2003]). Dies belegt auch eine Umfrage unter 480

Verkehrsexperten in den USA. Das Ergebnis zeigt jedoch auch, dass die Mehrheit der Experten dabei übereinstimmt, dass sich Verkehrsstörungen in erhöhten Reisezeiten auswirken und in einer Definition die zeitliche Komponente berücksichtigt werden muss [BERTINI O.D.]. In Abbildung 3.14 sind die fünf häufigsten Antworten aus der Umfrage dargestellt.

Die Definition von Verkehrsstörung sollte sich nach dem Ziel und dem Zweck der Anwendung richten. Störungen auf Autobahnen zeigen andere Charakteristiken als Störungen im Sekundärnetz. Wie detailliert eine Verkehrsstörung definiert wird, richtet sich nach der erforderlichen Sensitivität der Verfahren. In dieser Arbeit werden mikroskopische Verfahren zur Erkennung von Verkehrsstörungen bewertet. Sie arbeiten fahrzeugautonom während der Fahrt, indem gespeicherte streckenbezogene Fahrzeuggrößen ausgewertet und gefiltert werden. Durch den Streckenbezug ist damit prinzipiell eine genaue Lokalisierung der Störung möglich. So können die Störungen quasi kontinuierlich erkannt werden und nicht nur an diskreten Stellen wie bei Messquerschnitten. Es bedarf somit einer Definition von Verkehrsstörung, die sowohl eine genaue zeitliche als auch örtliche Lokalisierung erlaubt.




Abbildung 3.14.: Definitionen von Verkehrsstörung nach einer Umfrage in den USA (Quelle: [BERTINI O.D.])

Makroskopische Deskriptoren Makroskopische Kenngrößen, die an Messquerschnitten generiert werden, genügen dem geforderten Detaillierungsgrad nicht. Kumulative Kurven oder auf dem Fundamentaldiagramm basierende Definitionen haben den Zweck, lokal eine Aussage über den Verkehrszustand zu machen. Ein Stau wird dann erkannt, wenn er den Messquerschnitt passiert.

Neben der örtlichen und zeitlichen Lokalisierung ist die Anwendbarkeit der makroskopischen Definitionen kritisch. Dies gilt speziell für den in dieser Arbeit betrachteten Übergang zwischen freiem und gestautem Verkehr. Die in Abschnitt 3.3.1 aufgeführten Definitionen bieten keine exakten quantifizierbaren Aussagen, ab wann ein Streckenabschnitt gestaut ist.

Im Sinne einer fahrzeugbezogenen Erkennung des Verkehrszustands müssten die makroskopischen Deskriptoren im Fahrzeug abgreifbar und messbar sein. Das bedeutet, dass auch die Fahrzeugumgebung und andere Fahrzeuge dargestellt werden müssen. Dies ist prinzipiell durch eine Ausstattung mit Sensoren wie Radar möglich. Für die Schätzung von Verkehrsdichten müssten jedoch Sensorgrößen wie Abstände zu den umgebenden Fahrzeugen genau gemessen und ausgewertet werden.

Mikroskopische Deskriptoren Mikroskopische Deskriptoren eignen sich für die Beschreibung der Fahrt eines einzelnen Fahrzeugs. Dabei ist zu beachten, dass die Fahrt eines Einzelnen einem stochastischen Prozess unterliegt und nur eine Stichprobe darstellt. Es müssen also Rauschprozesse berücksichtigt werden. Hinzu kommt die individuelle Fahrweise. Aggressive Fahrer neigen zu stärkeren Beschleunigungswechseln als moderate Fahrer. Daher ist zu vermuten, dass die Beschleunigung für eine fahrerunabhängige Betrachtung nur bedingt geeignet ist.

Fahrzeugabstände und Reisezeiten können auch mikroskopisch aufgezeichnet werden. Bei der Messung der Abstände muss beachtet werden, dass neben den oben erwähnten Messfehlern auch hier Rauschprozesse zu berücksichtigen sind.

Wie oben beschrieben wurde, zeigt die Umfrage von BERTINI, dass Reisezeiten für viele Personen eine hohe Aussagekraft besitzen. Ein ortskundiger Fahrer kann bei einer Reisezeitenangabe recht gut abschätzen, ob die Strecke gestaut ist oder nicht. Denn nach einer Untersuchung von BOGENBERGER ET AL. (2006) bestimmt die Ortskenntnis neben der Persönlichkeit maßgeblich das subjektive Qualitätsempfinden der Verkehrssituation und der Verkehrsinformation. Prinzipiell gibt es jedoch keine allgemeinen Aussagen, ab wieviel Prozent zusätzlicher Reisezeit bzw. erhöhter Verlustzeit eine Strecke gestört ist. Weiter stellt sich die Frage nach der Reisezeit bei freiem Verkehr, die für jeden Fahrer unterschiedlich ist.

Eine hohe Aussagekraft für das Vorhandensein einer Verkehrsstörung liefern Fahrzeugstillstände. Jedoch können diese nur bei starken Verkehrsstörungen mit Stillständen verwendet werden. Dazu kommt der starke zeitliche Detektionsverzug.

Die vorangegangenen Abschnitte zeigen, dass bisher keine geeignete Definition für mikroskopische Verfahren existiert.

3.3.3. Mikroskopische Definition

Die bisher entwickelten mikroskopischen Verfahren sind auf verkehrsinformationsorientierte Architekturen ausgelegt. Die Informationen gehen in Verkehrsinformationsdienste und Routenführungen ein. Die Robustheit ist deshalb ein wichtiger Faktor, da eher langlebige Störungen gesucht werden und keine Schwankungen, die sich geringfügig auf den Verkehrsfluss auswirken.

Bei sicherheitsrelevanten Informationen, bei denen ein Fahrer vor möglichen Gefahren und Hindernissen gewarnt wird, ist eine schnelle und genaue Lokalisierung essentiell. Solche sicherheitskritischen Informationen stellen eine Hauptanwendung des entwickelten Verfahrens dar. Sie werden meist unter dem Begriff der **Lokalen Gefahrenwarnung (LGW)** zusammengefasst. Dabei handelt es sich um *eine visuelle und/ oder akustische Information, die den Fahrer auf eine voraus liegende Gefahr hinweist, die in direktem örtlichen Bezug zu seiner Fahrstrecke steht* [OBERT 2005]. Ziel ist es, den Fahrer frühzeitig zu warnen, um ihm genügend Zeit zu geben, sich auf die Situation einzustellen und zu reagieren. Insbesondere sollte er nicht vor einer Gefahr gewarnt werden, die er gerade durchfährt oder schon passiert hat. Das mindert die Akzeptanz späterer Meldungen. Die lokale Gefahrenwarnung ist also ein zeitkritischer Dienst, der zudem hohe örtliche Genauigkeit verlangt.

Noch anspruchsvoller an die örtliche Genauigkeit sind Anwendungen im Bereich der dezentralen Verkehrssteuerung. Dort sind schon kleinere Geschwindigkeitsgefälle interessant, wenn es darum geht, den Verkehr durch fahrzeugautonome Regler zu stabilisieren. Fahrerassistenzsysteme der Zukunft könnten zusätzliche Informationen, etwa von umgebenden Fahrzeugen über Fahrzeug-Fahrzeug-Kommunikation oder Baken, erhalten. Neben einer reinen Informationsdarstellung für den Fahrer liegt es nahe, diese auch zu nutzen, um die Kapazität einer Straße zu erhöhen. Solche Ansätze wurden im Teilprojekt Verkehrsleistungsassistenz (VLA) des Förderprojekts INVENT⁴ untersucht. Dort wurde simulativ gezeigt, dass die Berücksichtigung der Geschwindigkeiten und der Entfernung vorausfahrender Fahrzeuge mit Hilfe geeigneter verkehrsdaptiver Regler prinzipiell möglich ist [KATES & BOGENBERGER 2004][KATES ET AL. 2006].

Es ist denkbar, neben den aktuellen Fahrzeugpositionen und Geschwindigkeiten vorausfahrender ausgestatteter Fahrzeuge auch Informationen über die Position der Stoßwelle und der Ausfahrt zu berücksichtigen. Solche Regelungen sind jedoch nur dann von positivem Nutzen, wenn die erkannte Störungsposition mit der realen weitestgehend übereinstimmt. Sind die gemeldeten örtlichen Differenzen zu groß, kann sogar ein gegenteiliger Effekt verursacht werden. Brems beispielsweise ein Fahrzeug im Sinne einer Harmonisierung des Verkehrs zu früh ab, kann es im schlimmsten Fall sogar eine Störung auslösen. Für eine schnelle Stauauflösung ist es dagegen wichtig, eine schnelle Beschleunigung an der Störungsausfahrt zu erreichen, jedoch nicht vorzeitig.

Die Anwendung des neu entwickelten Verfahrens SWIM liegt insbesondere auf den sicherheitskritischen Anwendungsbereichen LGW und vorausschauende Regler. Dort ist die zeitnahe Erkennung und räumlich genaue Lokalisierung von Störungen von großer Bedeutung. Für die Bewertung dieser Anwendungen ist folglich neben einer entsprechenden Definition auch ein objektives Referenzverfahren erforderlich. Die Verfahren werden vorerst für Autobahnen bewertet. Daher wird die Definition für diesen Bereich ausgelegt.

⁴Intelligenter Verkehr und nutzergerechte Technik

Aus mikroskopischer Sicht hat das Auftreten einer Störung zur Folge, dass die Fahrzeuge abbremsen müssen und ihre Geschwindigkeit abfällt (siehe Abschnitt 3.2.1). Makroskopisch hat eine Störung eine Änderung des Fundamentaldiagramms zur Folge, da sich die quantitativen Zusammenhänge der makroskopischen Variablen ändern [BUSCH 1986]. Weiter markieren Stoßwellen gemäß Definition 3.2 die Randgebiete einer Störung. Diese Definition wird von HOOPS ET AL. für die Bewertung von Verfahren zur Erkennung von Störungen im Hinblick auf die Gesamtsystemeffektivität von Streckenbeeinflussungsanlagen (SBA) spezifiziert:

Definition 3.3 [Störung] Eine Störung stellt ein Geschwindigkeitsgefälle längs einer Strecke dar [HOOPS ET AL. 1999].

Für die genaue Lokalisierung der Ein- und Ausfahrt einer Störung werden obige Definitionen erweitert zu:

Definition 3.4 [Störung] Eine **Verkehrsstörung** ist definiert durch ein Abweichen der Geschwindigkeit vom vorausberechneten Fahrtverlauf. Der Übergang ist örtlich und zeitlich von einer Stoßwelle beschränkt. Der Ort der Störungsein- und -ausfahrt bestimmt sich durch den Ort des steilsten Gradienten der Geschwindigkeit im Gebiet der Stauflanke.

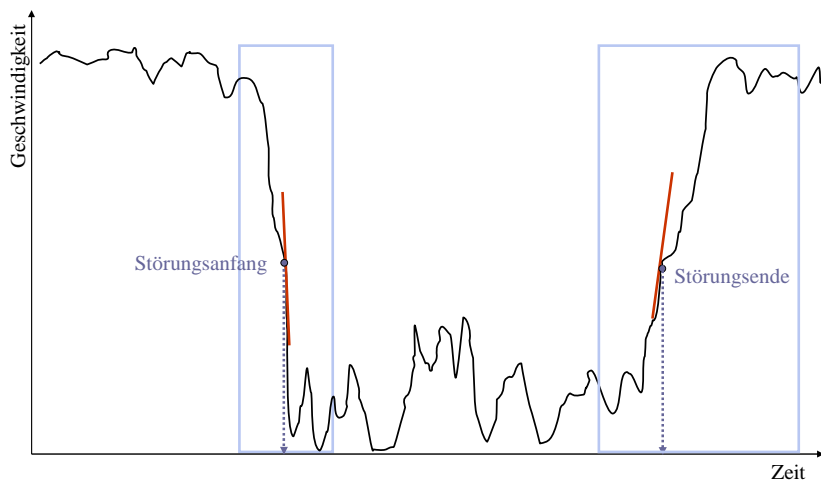


Abbildung 3.15.: Steilster Gradient im Geschwindigkeitsverlauf

Makroskopisch kann der Übergang zu einem veränderten Zustand als der Ort beschrieben werden, an dem sich die Stoßwelle zum Zeitpunkt der Betrachtung befindet. Mikroskopisch bedeutet er einen Übergang von einem Geschwindigkeitsniveau zum anderen. Dieses Gebiet wird in diesem Zusammenhang als **Stauflanke** bezeichnet. Die Position der Stauflanke wird durch den Ort des steilsten Gradienten angegeben. An dieser Position ist das Geschwindigkeitsgefälle bzw. der Geschwindigkeitsanstieg am Größten (siehe Abb. 3.15). Speziell für die Staueinfahrt ist dies der Ort der größten Gefahr.

4. Erkennung von Verkehrsstörungen

Dieses Kapitel gibt einen Überblick über automatisierte Verfahren zur Erkennung von Verkehrsstörungen. Die Verfahren werden anhand ihrer Datenquellen eingeordnet. Dabei wird schwerpunktmäßig auf die Erkennung mit stationären Daten eingegangen, da der Großteil der Arbeiten auf diesem Gebiet entstanden ist. Außerdem werden die vier XFCD-Verfahren detaillierter präsentiert, die im Rahmen dieser Arbeit bewertet werden.

4.1. Begriff der Störungserkennung

Störungserkennung ist ein wichtiger Bereich eines Verkehrsmanagementsystems. Dessen Ziel ist es, die Verkehrssicherheit zu verbessern und einen effizienten Verkehrsablauf sicherzustellen. Die ersten Arbeiten auf diesem Gebiet entstanden Mitte der 60er Jahre im Rahmen der Planung von Verkehrsmanagementzentren für Autobahnen im Ballungsraum [BUSCH 1991]. Seitdem sind Verfahren zur Störungserkennung ein fester Bestandteil im Praxisbetrieb. Der Begriff Störungserkennung lässt sich dabei nach BUSCH folgendermaßen definieren:

Definition 4.1 *[Störungserkennung]* **Störungserkennung** im allgemeinen Sinne umfasst alle Aktivitäten, die zu einer zeitlichen und räumlichen Lokalisierung von unvorhergesehenen Anomalien im Verkehrsablauf beitragen.

Je nach Definition von Störung kann auch die Bestimmung der Ursache der Störung dazugehören.

Voraussetzung für den praktischen Einsatz von Verfahren zur Störungserkennung sind Verkehrsüberwachungssysteme, die Verkehrsdaten in Realzeit erheben und verarbeiten. Das erste Verkehrsüberwachungssystem wurde 1961 in Detroit implementiert. Es war mit Fernsehkameras, Induktivschleifen und Wechselverkehrszeichen ausgestattet [OZBAY & KACHROO 1999]. Anfangs wurde die Störungserkennung rein manuell durchgeführt. Durch das steigende Verkehrsaufkommen und den damit verbundenen Anstieg an Unfällen und anderen Verkehrsstörungen wurde es jedoch immer wichtiger, Verkehrsstörungen schnell und genau zu detektieren. Das schuf den Wunsch nach automatisierten Verfahren. Das erste automatisierte Verfahren wurde 1968 von COURAGE und LEVIN entwickelt und in Chicago in Betrieb genommen [OZBAY & KACHROO 1999][SOLOMON 1991]. Die Entwicklungen auf dem IT-Sektor, insbesondere von realzeitfähigen Rechnern, ermöglichten ihre weitere Entwicklung.

Ursprünglich wurde die Hauptanwendung der Störungserkennung in der lokalen Verkehrssteuerung gesehen. Heute gewinnen überregionale Verkehrsinformationen, Verkehrsprognosen oder dynamische Zielführung zunehmend an Bedeutung.

Trotz vieler unterschiedlicher Ansätze, die dieses Thema behandeln, ist der Einsatz an Verfahren zur Störungserkennung in der Praxis nicht zufrieden stellend, so dass auch heute noch Forschungsbedarf an effizienten und exakten Verfahren besteht. Bei der automatisierten Erkennung von Störungen bzw. Übergängen zwischen Verkehrszuständen ist insbesondere die zeitnahe Detektion und die Modellierung der Flanken des Geschwindigkeitseinbruchs schwierig und stellt eine Herausforderung für Forschung und Wissenschaft dar.

Bis vor Kurzem wurden Verfahren hauptsächlich auf der Basis makroskopischer Daten wie mittlere Geschwindigkeiten am Detektor oder Belegungsgrade entwickelt. Deren Methoden werden nachfolgend schwerpunktmäßig diskutiert.

4.2. Verfahren auf Basis stationärer Datenquellen

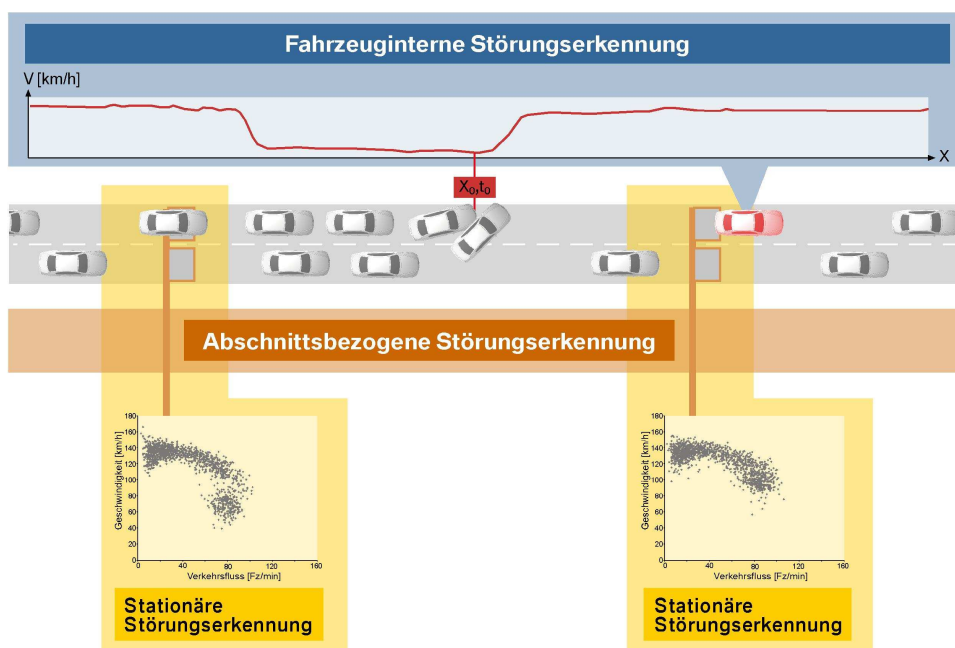


Abbildung 4.1.: Unterteilung der Verfahren nach örtlichen Kriterien

Verfahren zur Störungserkennung auf der Basis stationärer Daten können in lokale und abschnittsbasierte Verfahren unterteilt werden (siehe Abb. 4.1). Lokale Verfahren betrachten nur die Messgrößen und von ihnen abgeleitete Kennwerte an einem festen Ort über die Zeit. Dagegen berücksichtigen abschnittsbasierte Verfahren die Verkehrsgrößen an mehreren Messquerschnitten. Sie haben zum Ziel, eine Aussage über die Zustände zwischen den Detektoren zu

machen bzw. die Zusammenhänge stromabwärts und stromaufwärts in die Verkehrszustandsbestimmung miteinzubeziehen. So soll eine bessere Lokalisierung der Störung erreicht werden. Jedoch stellen diese Algorithmen höhere Anforderungen an die Messdatengenauigkeit. Bei Rampen stellt sich zusätzlich die Frage nach dem Flusserhalt, da der Ab- und Zufluss mit einberechnet werden muss.




Abbildung 4.2.: Abweichung der Prognose vom tatsächlichen Fahrtverlauf bei makroskopischen Daten an einem Messquerschnitt

Auf dem Gebiet der Störungserkennung existieren eine Vielzahl unterschiedlicher Algorithmen, die üblicherweise in verschiedene Verfahrensklassen eingeteilt werden. In der Literatur findet sich jedoch keine konsistente Aufteilung. Des Weiteren kommt es mit der Entwicklung neuer Verfahren und Verwendung von hybriden Verfahren zu Überschneidungen in der Einteilung. Aus diesem Grund werden nachfolgend die den Verfahren zugrunde liegenden Methoden unterschieden:

- Direkte Vergleiche,
- Katastrophentheorie,
- Zeitreihenmodelle,
 - ARIMA,
 - Wahrscheinlichkeitsmodelle,
 - Kumulative Kurven,
 - Filtertechniken,
- Klassifizierungsmethoden,
 - Clusteranalyse,
 - Support Vector Machine,
 - Hauptkomponentenanalyse,

- Künstliche Intelligenz,
 - Neuronale Netze,
 - Fuzzy Logik,
 - Genetische Algorithmen,
- Korrelations- und Regressionsanalyse und
- Verkehrsflussmodelle.

Daneben können Verfahren zur Störungserkennung in Mustererkennungsverfahren und prognosebasierte Verfahren unterteilt werden. Bei der Mustererkennung wird ein vorliegendes Muster mit der Realität verglichen. Dagegen betrachten prognosebasierte Verfahren die Differenz zwischen berechneter Prognose und Realität. Das Erreichen eines bestimmten Schwellenwerts ist dann ein Hinweis für das Auftreten einer Störung (siehe Abb. 4.2).

Allgemein können Verfahren zur Erkennung von Störungen auf der Basis stationärer Messdaten folgendermaßen beschrieben werden:

Definition 4.2 [Verfahren auf der Basis stationärer Daten] Sei F ein System von Funktionen, das eine Menge von Eingangsvektoren \vec{x}_i auf einen skalaren Wert abbildet. Weiter sei y_i eine Binärfunktion, die in Abhängigkeit von F eine Aussage über den aktuellen Verkehrszustand am Messquerschnitt i macht. Dann heißt F ein **Verfahren zur Erkennung von Störungen mit stationären Daten** und habe folgende Form:

$$F(t) = F(x_{i-n_l}^{\rightarrow}(t), x_{i-n_l}^{\rightarrow}(t-1), \dots, x_{i-n_l}^{\rightarrow}(t-j), \dots, \vec{x}_i(t), \dots, x_{i+n_r}^{\rightarrow}(t), \dots, x_{i+n_r}^{\rightarrow}(t-j); t)$$

Dabei sei

$$\vec{x}_i(t) = \begin{pmatrix} \vec{v}_i(t) \\ \vec{q}_i(t) \\ \vdots \end{pmatrix}: \text{ Vektor der Messwerte } \vec{v}_i(t), \vec{q}_i(t), \dots \text{ am Messquerschnitt } i \text{ zum Zeitpunkt } t \text{ (siehe Abb. 4.3)}$$

$$\vec{v}_i(t) = \begin{pmatrix} v_{i1}(t) \\ \vdots \\ v_{i n_{Spur}}(t) \end{pmatrix}: \text{ Vektor der Geschwindigkeit am Messquerschnitt } i \text{ zum Zeitpunkt } t \text{ auf den Spuren } 1, \dots, n_{Spur} \text{ (siehe Abb. 4.3)}$$

$$\vec{q}_i(t) = \begin{pmatrix} q_{i1}(t) \\ \vdots \\ q_{i n_{Spur}}(t) \end{pmatrix}: \text{ Vektor der Verkehrsstärke am Messquerschnitt } i \text{ zum Zeitpunkt } t \text{ auf den Spuren } 1, \dots, n_{Spur} \text{ (siehe Abb. 4.3)}$$

und

n_l, n_r : Anzahl benachbarter Messquerschnitte stromaufwärts und stromabwärts

n_{Spur} : Anzahl Spuren

j : Zeitfenster vergangener Werte

Übersteigt F einen Schwellenwert $\alpha, \alpha \in \mathfrak{R}$, liegt eine Störung $y_i(t) = 1$ am Messquerschnitt i zum Zeitpunkt t vor.

$$y_i(t) = 0, \quad \text{falls } F(t) \leq \alpha$$

$$y_i(t) = 1, \quad \text{falls } F(t) > \alpha$$

Bei prognosebasierten Verfahren mit Prognosehorizont T gilt:

$$y_i(t+T) = 0, \quad \text{falls } F(t) \leq \alpha$$

$$y_i(t+T) = 1, \quad \text{falls } F(t) > \alpha$$




Abbildung 4.3.: Stationäre Verkehrsdaten

Im Folgenden werden anfangs aufgezählte Methoden kurz beschrieben.

Direkte Vergleiche

Der intuitive erste Schritt bei der Entwicklung von Störungserkennungsverfahren ist die Verwendung *direkter Vergleiche*. Dabei werden Messdaten $\bar{x}(t)$ oder daraus ermittelte Kenngrößen mit vordefinierten Schwellenwerten verglichen. Oft werden mehrere Kenngrößen verwendet und in Form von Entscheidungsbäumen abgearbeitet. Die am häufigsten betrachteten Variablen sind Belegungsgrad, Volumen und Verkehrsfluss.

Die Verwendung von direkten Vergleichen hat den Nachteil, dass die Bestimmung der Schwellenwerte schwierig und nicht allgemein gültig ist. Außerdem werden nur Beobachtungen zum aktuellen Zeitpunkt t verwendet. Aufgrund der einfachen und effektiven Modellierung sind sie

jedoch sehr beliebt und es gibt zahlreiche Beispiele. Eines ist die einfachste Form der ACD-Methode von ZHANG ET AL. (1994), bei der entweder der Belegungsgrad oder die Geschwindigkeit zum Zeitpunkt t als Eingangsgröße verwendet werden.

Das Verfahren VKdiff ist dagegen ein abschnittsbasiertes Verfahren. Dabei wird zuerst eine Aussage am Messquerschnitt i gemacht [BUSCH 1986]:

$$VK_i(t) = \sqrt{\left(\frac{v_f - \bar{v}_i(t)}{v_f}\right)^2 + \left(\frac{k_i(t)}{k_{max}}\right)^2}$$

mit

$\bar{v}_i(t)$: Mittelwert der für ein Zeitintervall gemessenen Einzelgeschwindigkeiten zum Zeitpunkt t

$k_i(t)$: Mittlere geschätzte Dichte zum Zeitpunkt t

v_f : Geschwindigkeit bei freiem Verkehr

Schließlich vergleicht VKdiff die berechneten Werte zwischen zwei Messquerschnitten.

$$F(t) = VKdiff = VK_i(t) - VK_{i+1}(t)$$

Katastrophentheorie

Die Hauptidee der *Katastrophentheorie* besteht darin, dass bei der Änderung eines Zustandes der Wert einer Variablen plötzlich abfällt, während sich die anderen glatt und stetig ändern [PERSAUD & HALL 1989]. HALL übertrug diese Theorie auf den Verkehr. Dabei stellten er und PERSAUD unter Verwendung von 30-Sekunden-Daten fest, dass eine abrupte Änderung der Geschwindigkeit bei einer glatten Änderung des Flusses und des Belegungsgrades zu erkennen ist.

In der Literatur gibt es nur ein Verfahren, das diesem Modell zugrunde liegt. Dies ist der in Toronto eingesetzte McMaster Algorithmus [KIMBAUER O.D.]. Auf der Grundlage historischer Daten wird ein Musterdiagramm erstellt. Es enthält den Fluss und den Belegungsgrad und ist in vier Regionen unterteilt, die verschiedene Verkehrszustände darstellen. Dadurch ist eine Unterscheidung zwischen Staus an Engpässen und anderen Zwischenfällen möglich. Bei einem Übergang von freiem zu gestautem Verkehr wandert ein Punkt stetig in das Gebiet des gestauten Verkehrs, während die Geschwindigkeit stark abfällt. Analoges passiert beim Übergang gestaut-frei.

Die Katastrophentheorie ist sehr intuitiv und kann Diskontinuitäten erklären. Durch die Verwendung mehrerer Verkehrsvariablen ist sie bei Ausfall einer Messvariablen robuster als Algorithmen, die nur eine Verkehrsvariable verwenden. Allerdings ist die Kalibrierung komplex und aufwändig.

Zeitreihenmodelle

Zeitreihenmodelle eignen sich sehr gut für die Entwicklung prognosebasierter Verfahren. Sie können jedoch auch zur Mustererkennung eingesetzt werden. Ihr großer Vorteil liegt darin, dass keine großen Datenmengen bei der Implementierung abgespeichert werden müssen.

Zeitreihenmodelle lassen sich unterteilen in

1. ARIMA-Modelle,
2. Filtertechniken,
3. Wahrscheinlichkeitsmodelle und
4. Kumulative Ganglinien.

ARIMA-Modelle sind prognosebasierte Verfahren. Dabei wird die zu untersuchende Zeitreihe als Realisierung eines stochastischen Prozesses angesehen und anhand einer Klasse von linearen Modellen (p,d,q) modelliert.

ARIMA-Modelle eignen sich gut für die Modellierung von moderaten und hohen Flüssen. Durch die geringe Anzahl an Parametern ist die Berechnung einfach und schnell. Allerdings ist die Modellierung sehr aufwändig [BELZNER 2002]. Zudem verläuft die Detektion abhängig vom Prognosehorizont etwas verzögert [SMITH & DEMETSKY 1994]. AHMED (1983) entwickelte ein ARIMA-(0,1,3)-Modell zur Erkennung von Störungen auf amerikanischen Autobahnen.

Bei der univariaten Analyse wird nur eine Zeitreihe, also eine Messreihe x_t , betrachtet. Das hat zur Folge, dass nur eine Verkehrskenngröße in die Modellierung einfließt und der Zusammenhang zu weiteren Kenngrößen nicht berücksichtigt werden kann. Multivariate Modelle sind auf der anderen Seite sehr komplex zu modellieren und zeichnen sich durch ihre große Parameteranzahl aus. Ein Vergleich zwischen univariatem ARIMA-Modell und multivariaten STARMA- und VARMA-Modellen ist in KAMARIANAKIS UND PRASTACOS (2003) nachzuschlagen.

Filtertechniken dienen allgemein dazu, bestimmte Informationen hervorzuheben oder zu unterdrücken. In der Störungserkennung werden häufig Tiefpassfilter verwendet, um kurzzeitige Schwankungen im Verkehrsfluss herauszufiltern. Die Glättung führt jedoch häufig zu höheren Detektionszeiten durch die Berechnung von Mittelwerten oder anderen statistischen Größen.

Es gibt eine Vielzahl unterschiedlicher Filter, die in diesem Bereich zur Anwendung kommen. Ein effektiver, aber komplex zu modellierender Filter ist der Kalmanfilter. Die Parameteradjustierung der Filtermatrizen ist hierbei schwierig. BUSCH UND FELLENDORF zeigten, dass ein Kalmanfilter selbst bei unterschiedlichen Verkehrsbedingungen effektiv und schnell detektiert, wenn er mit einem geeignetem makroskopischen Verkehrsflussmodell verwendet wird

[BUSCH 1991]. Daneben gibt es einfache Tiefpassfilter wie exponential glättender Filter oder Mittelwert- und Medianfilter, die beispielsweise von STEPHANEDES UND CHASSIAKOS (1993) verwendet wurden.

Seit einiger Zeit nimmt die Verwendung von Wavelets bei der Detektion von Störungen zu. Wavelets haben gegenüber Fouriertransformationen den Vorteil, dass sie eine Funktion in eine Summe von flexibleren Funktionen zerlegen, die nach Zeit und Frequenz aufgelöst sind. Der Grad der Auflösung kann nach Wunsch bestimmt werden. Wavelets werden sowohl als Filter zur Extraktion von Eigenschaften genutzt als auch als Indikator für das Vorliegen einer Störung [TENG & QI 2003B].

Es liegt nahe, der stochastischen Natur des Verkehrs Folge zu leisten und Methoden der statistischen Entscheidungstheorie zu verwenden. Zudem ist es oft sinnvoll, die Aussage eines AID¹-Algorithmus mit statistischen *Wahrscheinlichkeiten* zu verbinden. Dazu ist allerdings, das nicht immer vorhandene a-priori-Wissen über die benötigten Wahrscheinlichkeiten, wie zum Beispiel der Wahrscheinlichkeit für das Auftreten einer Störung an einem betrachteten Messquerschnitt, notwendig. Wie bei den Filtern liegt jedoch auch hier der Nachteil in längeren Detektionszeiten durch die Berechnung von statistischen Größen. Beispiele sind Hypothesentests oder die Anwendung des Bayes'schen Algorithmus. Untersuchungen von LEVIN UND KRAUSE (1979) zu Bayes'schen Algorithmen zeigten gute Resultate für die Detektions- und Fehlalarmrate, aber eine hohe Detektionszeit bei der Offline-Evaluation. TENG UND QI (2003) entwickelten ein Verfahren zur Minimierung der Detektionszeit bei vorgegebener Fehlalarmrate. Ihre Zielfunktion beinhaltet das Verhältnis der Wahrscheinlichkeitsdichtefunktionen für normale und gestörte Verhältnisse.

Kumulative Verfahren beschreiben die Anzahl der Fahrzeuge, die, einem Referenzfahrzeug folgend, zu einem Zeitpunkt t eine Stelle durchfahren (siehe Abschnitt 3.3.1). Die Verfahren sind informativ und eignen sich zur Repräsentation von Details im zeitlichen Verlauf des Verkehrsflusses. Sie werden speziell für die Betrachtung benachbarter Messquerschnitte eingesetzt, bei denen sie Änderungen im Fluss detektieren sollen. Bei der Aufzeichnung der Daten über längere Zeiträume sind Abweichungen vom normalen Verkehrsfluss jedoch schwierig zu erkennen. Abhilfe schafft ein schräges Koordinatensystem, bei dem die betrachteten Kurven um einen Hintergrundfluss reduziert werden [CASSIDY & BERTINI 1999][MUÑOZ ET AL. 2002]. Die kumulativen Kurven der Verkehrsstärken und der Geschwindigkeiten ermöglichen eine gute Lokalisierung von Engpässen zwischen Detektorstationen [BOGENBERGER ET AL. 2006A]. Das Verfahren ist jedoch nicht automatisiert. Für die Störungserkennung wurden Verfahren von LIN UND DAGANZO (1997) entwickelt. Sie betrachteten kumulative Belegungsgrade.

¹automated incident detection (deutsch: automatische Störungserkennung)

Klassifizierungsmethoden

Die folgenden Methoden können unter dem Begriff Klassifizierungsmethoden zusammengefasst werden:

1. Clusteranalyse,
2. Support Vector Machine und
3. Hauptkomponentenanalyse.

Die *Clusteranalyse* ist ein typisches Mustererkennungsverfahren. Ziel ist es, eine Klasseneinteilung für die unterschiedlichen Verkehrszustände zu finden. In der Regel werden die Verkehrsdaten offline untersucht. Dabei werden aus den Datenpunkten, den Merkmalsvektoren, Untergruppen gebildet, die möglichst homogen sind. Die Einteilung der Klassen erfolgt auf der Basis der Daten und basiert nicht auf Expertenwissen. Aus diesem Grund wird die Clusteranalyse oft verwendet, um charakteristischer Merkmale herauszufinden, die dann im Algorithmus anhand von Schwellenwerten überprüft werden. In diesem Zusammenhang ist das Verfahren ATHENA zu nennen, bei dem zuerst eine Clusteranalyse durchgeführt wird und dann eine lineare Regression [DOUGHERTY ET AL. 1998].

Bei der Clusteranalyse ist die Qualität und der Umfang der Datenbasis wichtig, da nur Situationen erkannt werden können, die dort enthalten sind. Um robuste Aussagen zu treffen, muss daher eine ausreichend große Datenbasis vorhanden sein. Verbessert werden kann die Qualität durch eine adaptive Online-Berechnung, die die Aufnahme neuer Fälle erlaubt.

Support Vector Machine (SVM) ist ein überwachtes Maschinenlernverfahren, das speziell für die Lösung von Zwei-Klassen Mustererkennungsproblemen geeignet ist. Um diese zu trennen, wird eine optimale Hyperebene gesucht. SVM sind in ihrer Funktionsweise den Neuronalen Netzen sehr ähnlich. Allerdings unterscheiden sie sich in der Art ihrer Trainingsalgorithmen. Die Hauptarbeit im Training besteht aus der Lösung eines quadratischen Optimierungsproblems, um die sogenannten Support Vektoren zu finden, die am Rande der jeweiligen Merkmalsklasse liegen. Danach kann die Hyperebene bestimmt werden. SVM zeichnen sich durch ihre gute Verallgemeinerungsfähigkeit aus. Allerdings ist es wie bei Neuronalen Netzen wichtig, geeignete charakteristische Vektoren zu finden, die jede Klasse beschreiben können. Die erste Anwendung von Support Vector Machine im Bereich der Störungserkennung stammt aus Singapur und zeigte vergleichbare Ergebnisse zu einem vorwärtsgerichteten Neuronalen Netz und einem Probabilistischen Neuronalen Netz [YUAN & CHEU 2003].

Bei der *Hauptkomponentenanalyse* werden die Verkehrsdaten in einen Eigenschaftsraum mit niedriger Dimension transformiert, in welchem der Abstand jedes neuen Zustandsvektors zum Zentrum der Daten bei fließendem Verkehr berechnet wird. Eine Störung liegt vor, wenn die Summe der Hauptkomponenten einen bestimmten Schwellenwert übersteigt. Der große Vorteil bei dieser Methode liegt in der Analyse von ungestörten Daten, die leichter zu erhalten sind und

zahlreicher vorliegen. Für die Bestimmung der Hauptkomponenten müssen die Eigenwerte und Eigenvektoren der ausgewählten Eigenschaftsvektoren berechnet werden. Die Bestimmung des Schwellenwerts ist zudem problematisch. DOUGHERTY ET AL. (1998) fanden das Verfahren vielversprechend und benutzten eine Hauptkomponentenanalyse, um Störungen in simulierten Daten zu erkennen.

Künstliche Intelligenz

Unter Methoden der *Künstlichen Intelligenz* versteht man regelbasierte Algorithmen, die lernen, bestimmte Verkehrsmuster zu detektieren. Die Hauptanwendung liegt in der Mustererkennung, doch werden Neuronale Netze zum Beispiel auch für die Approximation von Funktionen verwendet. In den letzten Jahren wurden die Methoden der Künstlichen Intelligenz auch für die Detektion und Prognose von Verkehrskenngrößen und Verkehrsstörungen entdeckt und ein Großteil der entwickelten Verfahren entstanden auf diesem Gebiet. Bekannte Methoden sind:

1. Neuronale Netze,
2. Fuzzy Logik und
3. Genetische Algorithmen.

Neuronale Netze sind informationsverarbeitende Systeme. Ihre Funktionsweise ist der des menschlichen Gehirns nachempfunden. Dabei werden einzelne Neuronen meist in Schichten zusammengefasst und über gewichtete Verbindungen miteinander verknüpft.

Neuronale Netze eignen sich für die Modellierung von Modellen, bei denen eine mathematische Formulierung nicht oder nur sehr schwer möglich ist. Eine Hauptanwendung liegt in der Modellierung nicht-linearer Probleme. Neuronale Netze zeichnen sich durch ihre schnelle Art der Datenverarbeitung aus. Allerdings werden für das Lernen eines Neuronalen Netzes große Datenmengen benötigt. Weiter wird das Netz speziell für eine bestimmte Infrastruktur gelernt, welches wiederum zu einer schlechten Übertragbarkeit des Modells führt. Hier können adaptive Neuronale Netze Abhilfe schaffen. Üblicherweise werden mehrschichtige Neuronale Netze (MLF) verwendet. Im Laufe der letzten Jahre entstanden spezielle Arten Neuronaler Netze wie probabilistische Neuronale Netze (PNN) [RITCHIE & ABDULHAI 1997] oder konstruktive PNNs [JIN ET AL. 2002]. Des Weiteren wurde auch versucht, FCD und stationäre Daten mit Hilfe Neuronaler Netze zu fusionieren [THOMAS ET AL. 2001].

Fuzzy² Logik ist ein Mittel, um eine mathematische Beschreibung von nicht exakten Aussagen zu erhalten. Mit dieser Art von Modellierung ist es möglich, menschliches Wissen, insbesondere Expertenwissen, nachzubilden. Die grundlegende Idee basiert darauf, dass Elemente nicht nur binär, sondern auch anteilig einer Menge angehören können.

²deutsch: unscharf

Fuzzy Logik ist tolerant gegenüber fehlerhaften Daten. Die Methodik ist einfach zu verstehen und adaptiv. Ein wichtiges Einsatzgebiet der Fuzzy Logik liegt in der Steuerung und Regelung von Prozessen. Problematisch ist allerdings die Kalibrierung der Modelle. Dabei ist in der Regel eine große Anzahl an Berechnungen notwendig. Fuzzy Logik Modelle werden oft mit anderen Verfahren verknüpft. Ein Beispiel dafür ist ESE³, das verschiedene Verfahren mittels eines Fuzzy Modells verknüpft. Die Ausgangsgröße gibt die Wahrscheinlichkeit für das Vorliegen einer Störung an [BUSCH & GIO 1994].

Genetische Algorithmen sind iterative Suchalgorithmen, die zur Optimierung von Verfahren verwendet werden. Sie orientieren sich an den Prinzipien der biologischen Evolution, die sie stark vereinfacht algorithmisch nachbilden. Eine Menge an Lösungen wird im Laufe der Iteration durch bestimmte Evolutionsoperatoren verändert, um zum Schluss die in diesem Fall bestmögliche Lösung zu erhalten. So benutzen SRINIVASAN ET AL. (2001) ein Fuzzy-Modell, dessen Parameter mit Hilfe eines genetischen Algorithmus optimiert werden.

Korrelations- und Regressionsanalyse

Die *Korrelationsanalyse* überprüft, ob Zusammenhänge zwischen einzelnen Variablen bestehen. Die *Regressionsanalyse* untersucht die Form der Abhängigkeit zwischen den Merkmalen. Beide Analysemethoden werden in der Störungserkennung verwendet.

Korrelationsanalysen eignen sich für die Betrachtung von benachbarten Detektoren. Dabei wird angenommen, dass bei ungestörtem Verkehrsfluss der Verkehrszustand am stromaufwärtigen Messquerschnitt zeitlich verschoben am stromabwärtigen Messquerschnitt auftritt. Eine Störung kann damit aufgrund von plötzlichen Veränderungen in der Korrelationsfunktion erkannt werden. Diese Methode eignet sich insbesondere bei Verkehrszuständen mit geringen Volumensstärken [BUSCH 1991]. Nachteilig ist die etwas aufwändige Berechnung. Das Verfahren von ZOU UND LEVINSON (2003) wertet nur Verkehrsdaten eines Messquerschnitts aus. Als Indikator für den Übergang von freiem zu gestautem Verkehr dient die Veränderung der Kreuzkorrelation zwischen Verkehrsfluss und dem hochfrequenten Anteil der Dichte.

Bei der Regressionsanalyse wird versucht, eine Störung als Funktion verschiedener unabhängiger Variablen darzustellen. Die Methode ist aufgrund der geringen Parameteranzahl einfach zu implementieren. Wichtig ist eine gute Wahl der funktionalen Form und ihrer Parameter. TARKO UND ROUPHAIL (1993) verwenden eine lineare Regression, um Belegungsgrade in Reisezeiten zwischen einzelnen Links zu transformieren. Dabei werden jedoch lineare Zusammenhänge zwischen abhängigen und unabhängigen Variablen angenommen. KONDURI UND SINHA (2002) verwenden daher eine exponentielle Form für die Prognose von Störungen.

³Erweiterte Situationserkennung

Verkehrsflussmodelle

Verkehrsflussmodelle bilden den Verlauf des realen Verkehrsflusses und speziell seine Dynamiken mathematisch ab. Der Verkehr kann damit nicht nur an, sondern auch zwischen den Messstationen dargestellt werden. Da an den Detektoren in der Regel makroskopische Messgrößen vorliegen, eignet sich vorzugsweise eine makroskopische Modellierung. Neben der abschnittsweisen Betrachtung des Verkehrs ist die Verwendung von Expertenwissen von Vorteil. Durch die Abbildung von Verkehrsdynamiken kann eine frühere und genauere Detektion von Störungen zwischen den Messstationen ermöglicht werden. Das Problem hierbei ist eine genaue Abbildung des Verkehrs und der Störungsmuster.

Problematisch ist auch die Wahl von ungünstigen oder fehlerhaften Anfangsbedingungen, die sich möglicherweise aufrechterhalten oder aufschwingen. Aus diesem Grund verwenden viele Modelle einen Korrekturmechanismus. Ein Beispiel hierfür ist das Verfahren AZTEK⁴, welches auf einem makroskopischen Verkehrsflussmodell von PAYNE und CREMER basiert und als Zustands- und Störungsschätzer einen Kalmanfilter verwendet [MEIER ET AL. 2001]. Ein weiteres makroskopisches Verkehrsflussmodell ist das Verfahren UNRUHE IM VERKEHR, das von ZACKOR ET AL entwickelt wurde und als stochastisches Kontinuumsmodell beschrieben werden kann [HOOPS ET AL. 1999].

4.3. Verfahren auf Basis von FCD

Allgemein können FCD-Verfahren folgendermaßen beschrieben werden.

Definition 4.3 [*FCD-Verfahren*] Sei F ein System von Funktionen, das eine Menge von Eingangsvektoren \vec{z} auf einen skalaren Wert abbilde. Weiter sei y eine Binärfunktion, die eine Aussage über den aktuellen Verkehrszustand an Position x macht. Dann heißt F ein **FCD-Verfahren zur Erkennung von Störungen** und habe folgende Form:

$$F(t) = F(\vec{z}(t), \vec{z}(t-1), \dots, \vec{z}(t-j); t)$$

Dabei sei

$$\vec{z}(t) = \begin{pmatrix} v(t) \\ x(t) \\ \vdots \end{pmatrix}: \text{ Vektor der Fahrzeugmesswerte } v(t), x(t), \dots \text{ zum Zeitpunkt } t$$

$v(t)$: Geschwindigkeit zum Zeitpunkt t

$x(t)$: Position zum Zeitpunkt t

j : Zeitfenster vergangener Werte

⁴Automatische zeitlich-räumliche Störungserkennung

Übersteigt F einen Schwellenwert α , $\alpha \in \mathfrak{R}$ liegt eine Störung $y(t) = 1$ an Position $x(t)$ zum Zeitpunkt t vor.

$$\begin{aligned}y(x,t) &= 0, & \text{falls } F(t) &\leq \alpha \\y(x,t) &= 1, & \text{falls } F(t) &> \alpha\end{aligned}$$

Bei FCD-Verfahren werden also Zeitreihen aufgenommener Messgrößen analysiert. Nachfolgend werden die bisher in FCD-Verfahren verwendeten Methoden aufgeführt.

- Direkte Vergleiche,
- Zeitreihenanalyse,
 - Filtertechniken,
 - Wahrscheinlichkeitsmodelle,
 - Spektralanalyse und
- Künstliche Intelligenz (Fuzzy Logik).

Wie in Kapitel 2 beschrieben wurde, werden *FCD-Verfahren* in bakengestützte und mobilfunkgestützte Verfahren unterschieden. Diese Unterteilung wird im Folgenden beibehalten.

4.3.1. Bakengestützte Verfahren

Bei diesem Verfahren wird der Verkehr auf einem Abschnitt zwischen zwei Baken betrachtet. Aufgrund der genauen Definiertheit der Strecke werden die Daten, in der Regel Reisezeiten, mehrerer Fahrzeuge gemeinsam betrachtet (siehe Abb. 4.4). Außerdem können prinzipiell alle Methoden der stationären Störungserkennung angewandt werden.

HELLINGA UND KNAPP (1999) entwickelten drei bakengestützte Verfahren. Alle drei Verfahren (Confidence Limit Algorithm, Speed and Confidence Limit Algorithm und Dual Confidence Limit Algorithm) basieren auf Zeitreihenverfahren. Sie berechnen Mittelwerte und Varianzen der zwischen den Baken erhobenen Reisezeiten, um zwischen den Zuständen Stau und freien Verkehr zu unterscheiden. Das Ergebnis zeigte eine Überlegenheit des Speed and Confidence Limit Algorithmus gegenüber den anderen beiden Verfahren. Seine Darstellung war in der simulationsbasierten Untersuchung vergleichbar mit der des McMaster Algorithmus.

In Singapur wurde ein dem Confidence Limit Algorithmus von HELLINGA UND KNAPP ähnliches Verfahren entwickelt. Das Verfahren MOSES⁵ besteht aus einem einseitigem Hypothesentest, der einen Unterschied in den mittleren Reisezeiten zweier aufeinander folgender Gruppen

⁵Mobile Sensor and Sample-Based Algorithm

von FCD-Fahrzeugen untersucht [CHEU 2002]. Im Gegensatz zum Confidence Limit Algorithmus berechnet MOSES die Mittelwerte auf der Basis fester Fahrzeuggruppen und nicht zeitbasiert. Weiter wird die Reisezeitverteilung als normalverteilt und nicht logarithmisch normalverteilt angesehen und eine t-Statistik verwendet. Ziel ist die Nutzung des Verfahrens für die Verkehrsüberwachung und im Rahmen eines Mautsystems im innerstädtischen Autobahnbereich. Dazu soll ein Fahrzeug beim Passieren einer Bake dessen Identitätsnummer sowie einen Stichprobencode empfangen. Außerdem wird dem Fahrzeug eine für den Abschnitt geltende Identitätsnummer zugewiesen. An der stromabwärtigen Bake versendet das Fahrzeug diese ID zusammen mit der zurückgelegten Reisezeit.

WESTERMAN ET AL. (1996) entwickelten einen Ansatz zur Schätzung der mittleren Geschwindigkeiten auf einer Strecke. Diese beruht zum einen auf einer Schätzung des aktuellen Verkehrszustands auf der Basis eines Fundamentaldiagramms. Darauf aufbauend wird eine Bayes-Schätzung durchgeführt. In diese fließen neben den gesendeten auch die Geschwindigkeiten früherer Zeitperioden sowie historische Daten ein.

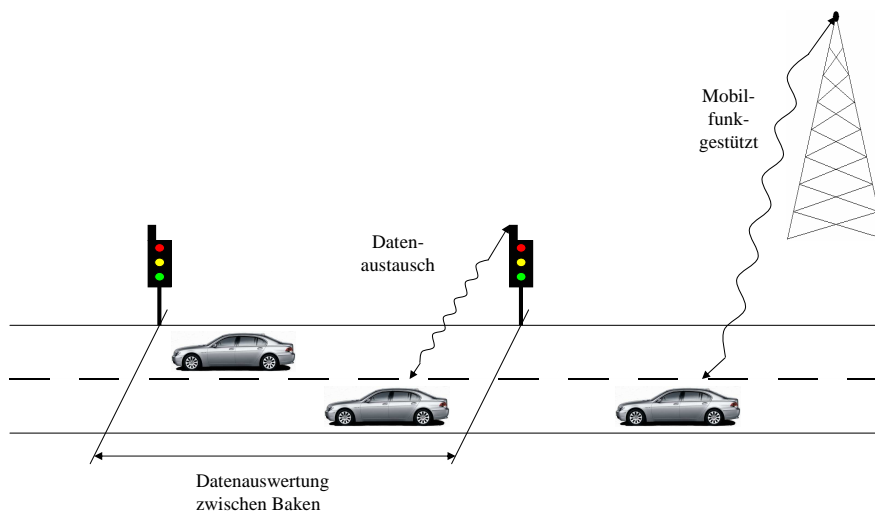


Abbildung 4.4.: Unterschied der Datenverarbeitung zwischen Baken- und Mobilfunkgestützten Verfahren

4.3.2. Mobilfunkgestützte Verfahren

Bei mobilfunkgestützten Verfahren erfolgt im Gegensatz zu bakengestützten Systemen die Erkennung üblicherweise im Fahrzeug. Dabei ist zu beachten, dass der Speicherplatz im Fahrzeug beschränkt ist. Schwellenwertverfahren und Zeitreihenmodelle haben den Vorteil, dass sie einfach zu implementieren sind und in der Regel keinen großen Speicherplatzbedarf beanspruchen.

Bei der Betrachtung streckenbezogener Daten ist die aussagekräftigste und am leichtesten zugängliche Größe die Geschwindigkeit. PETTY ET AL (1997) verwenden den gleitenden Mit-

telwert der vergangenen 20 Sekunden an Geschwindigkeitsdaten. Diese Daten werden zu Beschleunigungen abgeleitet und mit einem Schwellenwert verglichen. Der für Autobahnen entwickelte Algorithmus ist speziell auf die Erkennung der Position der Störung, also dem Ort des Beschleunigungs, und der Stärke der Störung vorgesehen.

Basierend auf den Arbeiten PETTYS entstand das Verfahren MOSAR⁶. Auch hier wird ein Schwellenwertverfahren mit vorgeschaltetem Filter verwendet [QI ET AL. 2002]. Die Zentrale meldet jedoch erst Stau, nachdem eine bestimmte festgelegte Anzahl an Meldungen empfangen wurde. Das Verfahren wurde für Schnellstraßen im innerstädtischen Bereich ausgelegt.

Auf der Basis einer Untersuchung des subjektiven Stauempfindens entwickelten ISHIDA ET AL. (2003) ein geordnetes Logit Modell. Dabei wurden Versuchsfahrten sowie Videobefragungen durchgeführt.

Unter der Annahme, dass Verkehr in bestimmten Situationen wie z.B. Stop-and-Go-Verkehr ein periodisches Verhalten aufweist, berechneten GÖSSEL ET AL. (2001) die Spektren der Geschwindigkeitsganglinie mit Hilfe der diskreten Fouriertransformation. Sie entdeckten, dass sich Spektren mit freien und zähfließenden Verkehr qualitativ kaum unterscheiden, jedoch Unterschiede zwischen freiem, Stop-and-Go Verkehr und dem Übergang zwischen verschiedenen Zuständen vorherrschen.

Jedoch gibt es auch Versuche, Methoden der künstlichen Intelligenz für die Störungserkennung im Fahrzeug anzuwenden. Bei der Deutschen Gesellschaft für Verkehrsdaten mbH (DDG) wird zu diesem Zweck eine zentralenseitige Fuzzy-Klassifikation eingesetzt. Die im Fahrzeug vorgefilterten Geschwindigkeitsdaten (siehe Kapitel 2) werden zusammen mit den erhobenen stationären Daten auf einem in Zeit und Ort diskretisierten Gitter fusioniert und gefiltert. Die resultierenden Merkmalsvektoren ergeben die Eingangsgrößen in den Fuzzy-Regler [SCHNÖRR 2000].

Mit dem Ziel, das Sendeaufkommen und die Speichergröße von FCD-Meldungen zu minimieren, wurde in Yokohama und Nagoya ein Feldversuch mit 226 Fahrzeugen des öffentlichen Verkehrs durchgeführt. Statt kontinuierlich Positionen des Fahrzeugs aufzuzeichnen, werden Zustände wie „kurze Fahrt“ und „kurzer Stop“ definiert. Die Daten werden dann gefiltert, um Sonderereignisse wie Parkvorgänge auszuschließen. Es entstehen einzelne abgeschlossene Fahrten, für die die Sequenz der Zustände analysiert wird. Die Verhältnisse der beiden Ereignisse geben eine Aussage über die Wahrscheinlichkeit eines Verkehrszustands im städtischen Bereich [SARVI ET AL. 20].

Die Reduzierung des Meldeaufkommens im innerstädtischen Bereich ist auch das Ziel der Arbeit von DEMIR ET AL. (2004). So soll ein Fahrzeug nur dann eine Meldung an eine Zentrale senden, wenn sich die Reisezeit in einem Abschnitt um einen Schwellenwert zu der früheren Reisezeit unterscheidet. Voraussetzung ist hier, dass dem Fahrzeug am Anfang der Strecke die aktuelle Reisezeit und der Schwellenwert über Rundfunk gesendet wird.

⁶Mobile Sensor Auto-Reporting Algorithm

In Berlin und einigen anderen Städten wurde ein Feldversuch unternommen, in dem Taxis zu FCD-Fahrzeugen ausgestattet wurden [SCHÄFER ET AL. 2002]. Diese senden kontinuierlich Daten an einen Zentralrechner. Da hier Zustandsinformationen wie „Warten“ oder besondere Ereignisse bekannt sind, wurde ein einfaches Schwellenwertverfahren für die Geschwindigkeit implementiert. Für München wurde ein Prototyp zur Reisezeitermittlung und -prognose entwickelt. Auf dessen Basis können Verkehrsstörungen differenziert nach Abbiegebeziehungen erkannt werden [LEONHARDT 2006].

4.4. Verfahren auf Basis von XFCD

Im Folgenden werden vier XFCD-Verfahren der BMW Group detaillierter vorgestellt und analysiert (siehe Tabelle 4.4). Sie werden im Rahmen dieser Arbeit softwaretechnisch umgesetzt und bewertet. Die Parameter der einzelnen Algorithmen sind im Anhang aufgeführt.

Verfahren	Methode
Fuzzy-Algorithmus	Fuzzy-Logik
Incognito	Filtertechnik
City-Algorithmus	Filtertechnik
Schwellenwertverfahren	Filtertechnik

Tabelle 4.4.: XFCD-Verfahren

4.4.1. Fuzzy-Algorithmus

Der Fuzzy-Algorithmus hat zum Ziel, Verkehrsstörungen auf Autobahnen zu detektieren. Dabei wird zwischen freiem und gestörtem Verkehrsablauf unterschieden. Der Algorithmus besteht aus zwei Modellen, von denen eines für die Detektion einer Staueinfahrt, das andere für die Detektion einer Stauausfahrt konzipiert ist. Der Schwerpunkt liegt jedoch in der Modellierung der Staueinfahrt.

Kenngrößen

HUBER (2001) bezeichnet die Geschwindigkeit, das Beschleunigungs- und das Bremsverhalten als die zentralen Größen für die Erkennung einer Störung. Weiter geben die Aktivierung von Blinker und Warnblinker wichtige Hinweise auf den aktuellen Verkehrszustand.

Der Indikator $s1$ für den Geschwindigkeitsabfall berechnet sich aus der Summe der Beschleunigungswerte der letzten Δt Sekunden:

$$s1(t) = \sum_{k=t-\Delta t}^t b(k)$$

Nach HUBER ist ein starker Geschwindigkeitsabfall innerhalb eines kurzen Zeitintervalls Δt ein Indikator für eine Störungseinfahrt. Das Bezugsintervall wird auf 10 Sekunden gesetzt. Unter der Annahme, dass Verzögerungen ab $1,0 \frac{m}{s^2}$ nur durch aktive Bremsingriffe durchzuführen sind, ergibt sich somit ein Geschwindigkeitsabfall von mindestens $35 \frac{km}{h}$, der auf Autobahnen als gefährlich einzustufen ist. Weiter gilt, dass nur Geschwindigkeitsabfälle unterhalb von $75 \frac{km}{h}$ betrachtet werden.

Der *Störungsindikator s2* soll Störungen erkennen, die sich durch langsames Einfahren in den Stau auszeichnen. Dazu wird die über die Zeit entstehende Fläche zwischen der aktuellen Geschwindigkeit und der Referenzgeschwindigkeit $75 \frac{km}{h}$ betrachtet. Die Größe der positiven Fläche ist ein Maß für die Stärke der Störung.

Indikator *s1* eignet sich somit, Geschwindigkeitsgefälle und Flanken einer Störung zu erkennen. Im Gegensatz dazu zeichnet sich Indikator *s2* durch seine Stabilität aus und ist damit das zentrale Kriterium bei der Detektion. *s1* wird für die räumliche Bestimmung der Störungseinfahrt verwendet.

Um Sondersituationen wie das Verlassen der Autobahn oder das Halten an einem Rastplatz auszuschließen, werden weitere Kriterien als Eingabegrößen für den Fuzzyregler gebildet. Die *Straßenkategorie* dient vor allem zur Überprüfung, ob sich das Fahrzeug auf einer Bundesautobahn befindet bzw. ob das Fahrzeug die Autobahn verlässt. Die Informationen über *Autobahnkreuze* und das Setzen des *rechten Blinkers* geben ebenfalls wichtige Hinweise über die aktuelle Straßenposition. Die eingeschaltete *Warnblinkanlage* dient als Zeichen für das Vorliegen einer Panne oder als Warnung für nachfolgende Fahrzeuge vor einer Störung.

Algorithmus

Der Algorithmus wertet sekundlich die Informationen der digitalen Karte, der Geschwindigkeit, des Blinkers und der Warnblinkanlage aus und verdichtet sie zu Kenngrößen, die wiederum die Eingangsgrößen für den Fuzzyregler bilden. Der Fuzzyregler bestimmt dann, welcher Verkehrszustand aktuell vorliegt. Der Regler besteht aus 8 Regeln, die die Daten anhand der Mamdani-Methode verarbeiten. Eine Staumeldung wird erzeugt, wenn die Ausgangsgröße einen Schwellenwert übersteigt. Die genaue Lokalisierung der Störung geschieht über eine rückwirkende Betrachtung des Indikators *s1* und der Warnblinkaktivität. Nachdem eine Stau-einfahrt erkannt wurde, wird der gleitende Mittelwert der Geschwindigkeit für die Bestimmung der Störungsausfahrt betrachtet.

4.4.2. Incognito

Ziel des Algorithmus Incognito⁷ ist die Schätzung der Verkehrslage auf Bundesautobahnen. Das Verfahren überprüft für jeden Zeitpunkt, ob das Fahrzeug in eine Störung hinein- oder hinausfährt. Es werden verschiedene Verkehrszustandsklassen unterschieden.

Kenngrößen

Die Eingangsdaten von Incognito bestehen aus sekundlichen Daten der Geschwindigkeit, des Bremsverhaltens und der Straßenkategorie. Mit Hilfe der *Straßenkategorie* wird überprüft, ob sich das Fahrzeug auf einer Autobahn befindet oder nicht. Neben der *Geschwindigkeit* und dem *Bremsverhalten* ist das *normierte Beschleunigungsrauschen* R_n die Hauptkenngröße für die Störungserkennung. Für das normierte Beschleunigungsrauschen wurde ein zeitliches Bezugsintervall von 10 Sekunden festgelegt. Dabei soll die Abhängigkeit von der mittleren Geschwindigkeit \bar{v} verhindern, dass kurzfristige starke Bremsmanöver bei hohen Geschwindigkeiten nicht fälschlicherweise als Indiz für eine Störung gewertet werden.

Algorithmus

Häufige Beschleunigungswechsel durch Anfahren und Abbremsen führen im Stau zu hohen Varianzen in der Beschleunigung. Durch die Abhängigkeit von der mittleren Geschwindigkeit führt das zu großen Werten von R_n . Bei der Einfahrt in eine Störung kommt es zu einem starken Geschwindigkeitsgefälle, welches ebenfalls einen hohen Wert des normierten Rauschens bewirkt. Eine Störung wird dann erkannt, wenn der Wert des normierten Rauschens einen bestimmten Schwellenwert übersteigt und gleichzeitig ein Verzögerungskriterium während der letzten 10 Sekunden erfüllt wurde.

In der sogenannten Stauanalyse werden jeweils die oben genannten Staukriterien überprüft und rückblickend für die letzte Minute betrachtet. Je nachdem, ob und wie lange ein Fahrzeug im Stau zum Halt kommt, wird zwischen den Verkehrsqualitätsstufen zähfließend, stockend und stehend unterschieden. Wenn diese Kriterien innerhalb der vergangenen 60 Sekunden nicht auftraten, ist ein potentieller Staukopf, also der Übergang vom gestörten in den freien Verkehr erkannt. Eine Meldung wird jedoch erst, nachdem 90 Sekunden keine erneute Staueinfahrt gemeldet wird, generiert. Schließlich kann das Auftreten von kurzzeitig sehr kleinen Geschwindigkeiten ebenfalls zu einer Staumeldung führen.

Bei freiem Verkehrsfluss werden ebenfalls drei Qualitätsstufen anhand ihres Bremsverhaltens und ihrer Geschwindigkeit in den letzten 60 Sekunden unterschieden. Annahme ist, dass sich

⁷In Car Originated Information for Telematic Operation

Bremsaktionen mit zunehmender Verkehrsstärke und Abhängigkeit vom Fahrzeugkollektiv häufen [BREITENBERGER 1997].

4.4.3. City-Algorithmus

Das Verfahren hat zur Aufgabe, Störungen im innerstädtischen Bereich zu detektieren. Da zur Zeit seiner Entwicklung die Informationen der digitalen Karte noch nicht technisch nutzbar waren, verwendet dieses Verfahren nur die Geschwindigkeit als Eingangsgröße in den Algorithmus.

Kenngößen

Der Verkehr im innerstädtischen Straßenverkehrsnetz ist geprägt von häufigen Geschwindigkeitswechseln, immer wieder unterbrochen durch Halte an Lichtsignalanlagen. Aus diesem Grund basiert der von HARTWIG entwickelte Algorithmus auf der Erkennung einer unruhigen Fahrweise. Während sich die Fahrzeuge im Bereich des freien Verkehrs entsprechend ihrer Wunschgeschwindigkeit, nur eingeschränkt durch das herrschende Geschwindigkeitslimit, bewegen können, muss sich ein Fahrer bei abnehmender Verkehrsqualität in seiner Fahrweise nach den umgebenden Fahrzeugen richten und sich ihnen anpassen. Das hat zur Folge, dass es zu vermehrten, ausgeprägten Wechseln von Beschleunigung und Bremsen kommt. HARTWIG (2001) schlägt aus diesem Grunde vor, die *Extrema im Geschwindigkeitsprofil bezogen auf ein festgelegtes Zeitintervall und ein festgelegtes Ortskriterium* zu analysieren. Dabei deuten viele Wechsel in der Beschleunigungsrichtung innerhalb eines kurzen Zeitraumes darauf hin, dass eine gestörte Verkehrssituation vorliegt. Bei kleinen Geschwindigkeiten oder vorkommenden Stillständen ist zu beachten, dass sich in kurzer Zeit nur wenige Beschleunigungswechsel ereignen. Aus diesem Grund werden die Wechsel zusätzlich in Abhängigkeit des Ortes bestimmt. Um die naturgemäß vorkommenden Schwankungen in der Geschwindigkeitsganglinie zu berücksichtigen und nicht fälschlicherweise als Störung zu werten, muss zwischen den Geschwindigkeitsextrema eine Mindestdifferenz vorliegen.

Algorithmus

Die Detektion einer Störung basiert auf zwei Kriterien. Um eine Störung zu erkennen, muss die Anzahl der örtlichen und der zeitlichen Wechsel einen Grenzwert übersteigen. Das zweite Kriterium führt zu einer Meldung, wenn das Fahrzeug eine bestimmte Haltezeit aufgrund möglicher Straßensperrungen erreicht hat. Damit ein Halt an einer Lichtsignalanlage nicht als eine Störung gewertet werden soll, muss eine Störung eine Mindestlänge besitzen.

Eine Ausfahrt aus einer Störung wird erkannt, wenn das Fahrzeug stark beschleunigt und die Beschleunigung innerhalb eines bestimmten Weg- oder Zeitintervalls eine Grenzbeschleunigung

übersteigt. Danach folgt eine ruhige Weiterfahrt mit geringen Geschwindigkeitsschwankungen. Um gemäßigte Fahrer zu berücksichtigen, werden zusätzlich die Wechsel in der Beschleunigungsrichtung und ihre Abnahme im Geschwindigkeitsverlauf betrachtet. Dabei muss allerdings eine minimale Geschwindigkeitsgrenze erreicht sein [HARTWIG 2001].

4.4.4. Schwellenwertverfahren

Das Schwellenwertverfahren ist der aktuellste der vier Algorithmen. Zum Zeitpunkt seiner Entstehung war es technisch bereits möglich, zusätzliche Informationen der digitalen Karte abzugreifen und für die Entscheidungsfindung miteinzubeziehen. Der Algorithmus ist für alle Straßenklassen konzipiert und modulhaft aufgebaut. Den Kern bildet das Verfahren zur Erkennung von Verkehrsstörungen. Daneben existieren Module, die Ausnahmesituationen oder Einflussfaktoren identifizieren, bei denen die Störungserkennung angehalten oder verzögert wird. Ergebnis ist das Vorliegen des Verkehrszustands frei oder gestaut.

Kenngrößen

Primär verwendete Größe ist die mittlere *Geschwindigkeit* über 60 Sekunden. Die Informationen der *digitalen Karte* werden auch hier genutzt, um Sondersituationen wie Halten an Rastplätzen oder ähnliches auszuschließen. Parkvorgänge oder das Absetzen von Personen stellen Sondersituationen im Verkehrsablauf dar, die irrtümlicherweise als Störung erkannt werden können. Um das zu vermeiden, werden die Informationen über den Radeinschlag, den Türen- und Gangstatus ausgewertet. Des Weiteren beeinflussen Faktoren wie Wetter, Straßenverlauf und Straßenbeschaffenheit die Fahrweise und damit das Geschwindigkeitsprofil. Aus diesem Grund werden die Daten Scheibenwischer, Nebelleuchte, Abblendlicht, Temperatur und Radeinschlag ausgewertet und gegebenenfalls eine Anpassung der Schwellenwerte vorgenommen. Außerdem kann die Entfernung von Kreuzungen abgegriffen und somit festgestellt werden, ob ein Fahrzeug verlangsamt, weil es sich einer Kreuzung nähert, oder aufgrund eines Staus.

Algorithmus

Die Grundlage für den Algorithmus bildet das Verfahren zur automatischen Stauererkennung (ACD-Methode) von ZHANG ET AL. (1994). Dazu wird der Geschwindigkeitsbereich in drei Bereiche unterteilt (siehe Abb. 4.5). Unterschreitet der gleitende Geschwindigkeitsmittelwert den Schwellenwert $S1$ für das unterste Geschwindigkeitsniveau, befindet sich der Verkehr im potentiellen Staubereich. Dort wird pro Zeitschritt der Wert der Stauvariablen s_{Stau} um 1 erhöht, bis der Grenzwert $S3$ erreicht wird. Erst dann wird Stau angezeigt. Kurzzeitiges Überschreiten der Geschwindigkeit in den mittleren Geschwindigkeitsbereich, den Übergangsbereich, wird

nicht als Phasenübergang gewertet, vielmehr werden beide Zustandszähler s_{Stau} und s_{Frei} um einen Teilbetrag $K1$ erhöht. Erst wenn die Geschwindigkeit den obersten Schwellenwert $S2$ für eine bestimmte Zeit $S5$ überschritten hat, wird s_{Stau} wieder zu Null gesetzt. Dies soll verhindern, dass ein kurzzeitiger Geschwindigkeitsanstieg als Ausfahrt aus dem Stau deklariert wird. Analoges gilt für den Übergang frei zu gestaut.

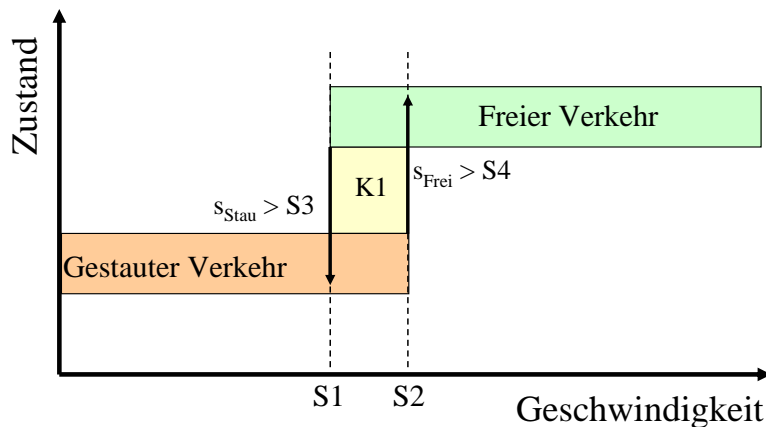


Abbildung 4.5.: Geschwindigkeitsbereiche des Schwellenwertverfahrens

Das Verfahren soll auch Verkehrsstörungen im innerstädtischen Bereich detektieren. Dazu wird im Kreuzungsbereich eine modifizierte Geschwindigkeitsganglinie verwendet. Unter der Annahme, dass ab einer festgelegten Distanz vor einer Kreuzung der Bremsvorgang einsetzt und durchschnittliche Wartezeiten an Kreuzungen bis zu 60 Sekunden andauern können, werden in diesem Bereich die Geschwindigkeitswerte durch die gleitenden Mittelwerte von vor 60 Sekunden ersetzt [HAUSCHILD 2003]. Voraussetzung ist die Unterschreitung des Schwellenwerts $S1$.

Liegt ein Ausnahmefall vor, wird die Detektion unterbrochen. Erst ab einer Dauer von 3 Minuten wird ein Reset durchgeführt, bei dem alle Variablen zu Null gesetzt werden.

4.5. Luft- und personen-basierte Verfahren

Neben stationären Daten und FCD gibt es zwei weitere Datenquellen, die für die Erkennung von Störungen verwendet werden können:

- Datenerfassung aus der Luft und
- Nutzung von Fahrerinformationen.

Der Vorteil der *Fernerkundung* liegt in der Erfassung großflächiger Gebiete. Wie Abschnitt 2.3.3 beschreibt, bietet dabei die Radarfernerkundung die einzige wetterunabhängige Methode der Datenerfassung aus der Luft. Mit ihr ist es außerdem möglich, die Geschwindigkeit einzelner, sich bewegender Fahrzeuge direkt zu erfassen. In einem Pilotprojekt der BMW Group mit der

AeroSensing Radarsysteme GmbH wurde diese Methode näher untersucht. Zu diesem Zweck wurde ein Abschnitt der Rosenheimer Straße im Zentrum Münchens im November 1999 in einem Intervall von 15 Minuten überflogen. Ein prototypisches Verfahren zur automatisierten Detektion der Fahrzeuge und ihrer Geschwindigkeiten wurde entwickelt [HOLZ 2005].

Die *personen-basierte Störungserkennung* nutzt den Sensor „Mensch“ als Datengrundlage. Durch die verbale Information können die Position, der Typ und die Stärke der Störung besser beschrieben werden. Zusätzlich sind keine hohen Anschaffungskosten und Unterhaltskosten für die Erfassungssysteme zu tragen. Eine Kalibrierung wie bei den oben vorgestellten Verfahren ist nicht notwendig. Allerdings ist die Störungserkennung auf den Beitrag Einzelner für die Allgemeinheit angewiesen. Ein Beispiel hierfür sind die Staumelder der Rundfunksender wie die Bayern3ver, die sich freiwillig als Melder zur Verfügung stellen. Die Qualität der Erkennung ist in hohem Maße von der Anzahl der Anrufer abhängig. Ein weiteres Hauptproblem liegt im „Abmelden der Staus“. Während das Auftreten einer Störung eine offensichtliche Änderung im Verkehrsablauf darstellt, wird selten das Auflösen einer Störung gemeldet. Dazu kommen Falschmeldungen und eine hohe Ungenauigkeit durch die von Person zu Person unterschiedliche subjektive Definition von Stau und anderen Verkehrszuständen.

Floating Phone Data zeigen durch die hohe Verbreitung an Mobiltelefonen ein großes Potential für die Störungserkennung und die Nutzung von Verkehrsinformationsdiensten. Die zurzeit laufenden Feldtests dienen vor allem der Untersuchung der Machbarkeit. Die Methodik basiert vom Grundsatz her auf dem FCD-Ansatz der DDG, bei dem Perlenketten von Reisezeiten bzw. Positionen übertragen werden [SCHLAICH 2005].

4.6. Schlussfolgerungen

Seit der Entwicklung des ersten AID-Systems wurde eine Vielzahl von Verfahren zur automatisierten Störungserkennung entwickelt. Während in Bayern die Verkehrsdaten hauptsächlich automatisiert verarbeitet werden, zeigt eine Studie von XIE UND PARKANY (2002) aus dem Jahre 2001, dass in den USA 53% der Befragten mit den implementierten AID-Systemen nicht zufrieden waren. Die häufigsten Argumente gegen die Verwendung automatisierter Systeme waren deren Fehlfunktionen, hohe Fehlalarmraten und lange Detektions- bzw. Verifikationszeiten. Jedoch wurden auch unhandliche Installationen, Bedienbarkeit und nicht erfolgreiche Realzeitfähigkeit bemängelt. Aus diesem Grund setzten nur 25% der befragten Verkehrsmanagementzentralen ein automatisiertes Störungserkennungssystem für die primäre Detektion ein. Videoüberwachung wurde in 96% der Fälle als Verifikationsverfahren verwendet.

Die personen-basierte Störungserkennung zeigt durch die hohe Ausstattung an Mobiltelefonen ein großes Potential. Jedoch sollte trotz aller Vorteile, die für diese Methodik sprechen, nicht

vergessen werden, dass diese immer abhängig von der Meldebereitschaft der Verkehrsteilnehmer ist. Durch die Subjektivität der Aussagen ist es schwer, eine objektive Verkehrserfassung zu erhalten. Manuelle Erkennung ist arbeitsintensiv und leidet unter Fehlverhalten oder Unaufmerksamkeiten. Insgesamt gesehen ist eine automatisierte, von menschlichen Fehlern unabhängige Detektion wünschenswert. Die Datenerfassung ist wie bei FCD netzhaft und ausstattungs-ratenabhängig.

Induktivschleifen sind die in der Praxis üblichen Datenerfassungssysteme. Aus diesem Grund stammen fast alle entwickelten und implementierten Algorithmen aus diesem Bereich. Die Qualität der existierenden Verfahren ist jedoch sehr schwer einschätzbar. Die in der Literatur dargestellten Ergebnisse sind aufgrund unterschiedlicher Definitionen der Gütekriterien schwer vergleichbar. Hinzu kommt, dass sich die untersuchten Strecken in der Anzahl der Messquerschnitte, den Detektorabständen, den Zeitintervallen oder anderen geometrischen Verhältnissen unterscheiden, welches einen Vergleich der Ergebnisse erschwert. Eine Untersuchung von verschiedenen Verfahren zur Gesamtsystemeffektivität von Streckenbeeinflussungsanlagen aus dem Jahre 1999 legt dar, dass die Güte der Verfahren systematisch vom Testfeld sowie der Datenqualität abhängt [HOOPS ET AL. 1999]. Dies zeigt die Problematik der Übertragbarkeit von stationären Erkennungsverfahren auf andere Strecken und Umgebungen. FCD-Verfahren werden dagegen nicht auf ein spezielles Testfeld zugeschnitten, sondern für bestimmte Straßenkategorien entwickelt.

Fakt ist, dass die Qualität der heutigen Systeme noch Raum für Verbesserung birgt. HOOPS ET AL. zeigten für stationäre Daten, dass selbst bei sehr guten Verfahren noch Optimierungspotential vorhanden ist. Für FCD-Verfahren gibt es bisher kaum Aussagen über ihre Qualität. Bei der Ereigniserkennung wird in der Regel der Verlauf der Geschwindigkeit analysiert. Hier liegt die Schwierigkeit in der Differenzierung von Störungen und Manövern, die nicht auf einer Störung basieren, wie Überholvorgänge, Abbremsen durch einscherende Fahrzeuge oder, außerhalb des Autobahnbereichs, aufgrund von Parkvorgängen.

Eine Qualitätssteigerung ist durch die gemeinsame Betrachtung der unterschiedlichen Verfahren zu erwarten. Neben der Fusion von Verfahren einer einzigen Datenquelle wird in Zukunft die Datenfusion unterschiedlicher Datenquellen (stationär, FCD oder luftbasiert) und ihrer Verfahren von Bedeutung sein. Diese können im Weiteren auch zur Verifikation genutzt werden. Speziell die Fusion von mobilen Rohdaten mit stationären Daten ist heutzutage von großem Interesse. Verfahren mit stationären Daten werden um FC-Daten erweitert, um die örtliche und zeitliche Detektion zu verbessern. Ein Beispiel hierfür ist AZTEK mit FCD [HORTER ET AL. 2004].

5. SWIM – Stoßwellen Erkennung mittels Interventionsmodell

In diesem Kapitel wird die Entwicklung und Funktionsweise des Verfahrens SWIM beschrieben. Das Ziel von SWIM ist eine frühzeitige und robuste Erkennung von Stauflanken auf Basis fahzeuggenerierter Daten. Die Störungserkennung in SWIM basiert auf zwei Interventionsmodellen, die Änderungen im Geschwindigkeitsniveau und starke Geschwindigkeitsgefälle erkennen. Zusätzlich gibt es einen Funktionsblock, der fehlerhafte Daten detektiert.

5.1. Anforderungen an den Algorithmus und gewählter Ansatz

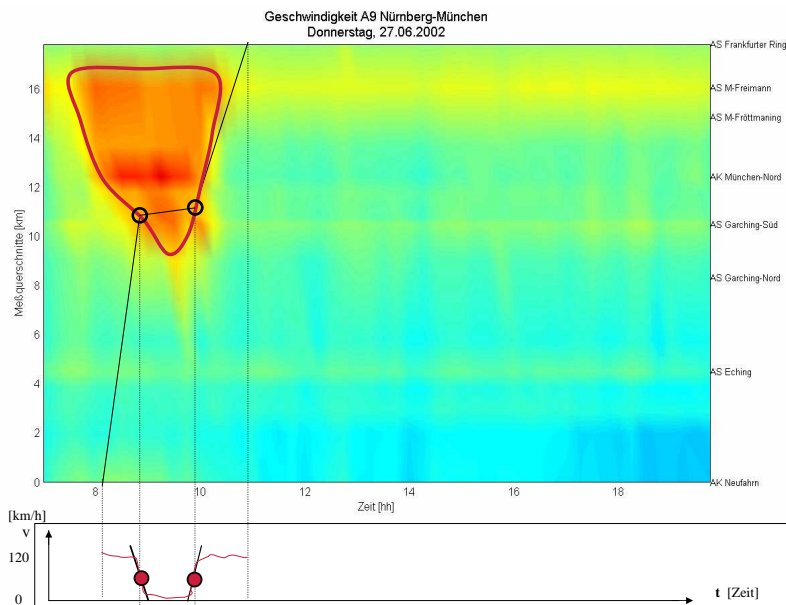


Abbildung 5.1.: Zeitlich-räumliche Abtastung des Verkehrs

Der Verkehrsfluss allgemein zeigt eine zeitliche und räumliche Dynamik, welche dazu führt, dass sich das Ausmaß und die Position einer Verkehrsstörung mit der Zeit ändern. Um diese zu erkennen wird, je nach Datenquelle, das zweidimensionale Geschwindigkeitsfeld eindimensional abgetastet (siehe Abb. 5.1). Beim Abtasten von stationären Daten befindet sich der Beobachter ortsfest während sich bei einer fahrzeugautonomen Erkennung der Beobachter, d.h. das Fahrzeug, zusätzlich mitbewegt.

Mit Hilfe des Algorithmus sollen Stauflanken detektiert werden, um nachfolgende Fahrer über das zu erwartende Geschwindigkeitsgefälle möglichst genau zu informieren. Wäre der Verkehr

deterministisch, könnte jedes Geschwindigkeitsgefälle gemäß einfacher Kriterien wie beispielsweise Schwellenwertverfahren, zuverlässig erkannt und gemeldet werden. Die stochastischen Eigenschaften des Verkehrsflusses führen jedoch dazu, dass im Fahrtverlauf auch Schwankungen vorkommen, die nicht auf eine Störung zurückzuführen sind (siehe Abschnitt 3.2.1). Diese machen sich insbesondere in den Geschwindigkeitszeitreihen jedes Fahrzeugs als auch in den Geschwindigkeitszeitreihen unterschiedlicher Einzelfahrzeugsdaten an einem ortsfesten Detektor bemerkbar. Um diese transienten Phänomene von solchen zu unterscheiden, die sich weiter fortpflanzen, wird ein Ansatz verfolgt, der sowohl die Stochastik des Verkehrs, als auch die Abhängigkeit der Fahrt vom Verkehrskontext berücksichtigt.

Die fahrzeuginternen Daten eines Fahrzeugs zu einem einzelnen Zeitpunkt genügen nicht, um den Verkehrszustand umfassend zu beschreiben. Zum Beispiel ist ein kurzzeitiges Beschleunigen oder Abbremsen in der Regel auf ein Überholmanöver zurückzuführen und bedeutet nicht sofort eine Einfahrt in einen Stau. Die Betrachtung vergangener Werte der Fahrzeugtrajektorie kann hier Abhilfe schaffen. Da für eine kleinräumige Regelung der Fahrzeuge mit Vorausschau eine zeitnahe Erkennung essentiell ist, muss eine optimale Balance zwischen Robustheit durch Filterung und einer kurzen Erkennungszeit gefunden werden.

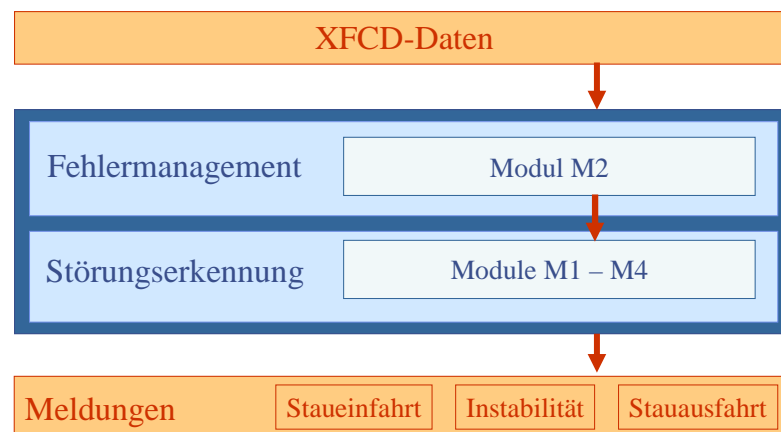


Abbildung 5.2.: Allgemeine Struktur von SWIM

In Abbildung 5.2 ist die allgemeine Struktur von SWIM dargestellt. Das Verfahren basiert auf der Verwendung fahrzeuggenerierter Daten. Für seine Qualität ist neben der Wahl der Methodik die Wahl aussagekräftiger Kenngrößen entscheidend. Das neue Verfahren bildet den Geschwindigkeitsverlauf nach. Die Geschwindigkeit wird als der aussagekräftigste mikroskopische Deskriptor angesehen.

Zu jedem Zeitschritt werden die an den Bussen vorliegenden XFC-Daten in SWIM eingelesen, untersucht und der Fahrt ein Verkehrszustand zugeordnet. Dabei unterscheidet SWIM intern die Zustände frei, instabil und gestört. **Instabiler Verkehr** bezeichnet in diesem Zusammenhang den Verkehrszustand im Übergang zwischen freiem und gestörtem Verkehr. Dieser markiert

signifikante Geschwindigkeitsgefälle auf ein mittleres Geschwindigkeitsniveau, bei dem sich die Fahrzeuge bereits deutlich gegenseitig beeinflussen.




Abbildung 5.3.: Modellierte Zustandsübergänge innerhalb von SWIM

Innerhalb von SWIM sind somit die Übergänge

- frei → instabil,
- frei → gestört,
- instabil → frei,
- instabil → gestört und
- gestört → frei

möglich (siehe Abb. 5.3). Von diesen Übergängen interessieren vor allem die Übergänge zwischen freiem und gestörtem Verkehr. Diese werden als Stau einfahrt bzw. Stau ausfahrt aufgefasst und mathematisch modelliert.

In dieser Arbeit erfolgt die Störungserkennung auf der Basis eines linearen Filtermodells, das der Stochastik des Verkehrsgeschehens Rechnung trägt und interne Zusammenhänge modelliert. Um gestörten Verkehr von ungestörtem zu unterscheiden, besteht der Ansatz in der Modellierung der natürlichen Schwankungen im Verkehr. Daher wird zuerst ein Modell für den freien Verkehr entwickelt. Die Störung wird dann durch ihre Differenziertheit zum ungestörtem Verkehr erkannt.

Ein univariates ARIMA-Modell, welches eine einzelne Zeitreihe betrachtet, dient zur Modellierung der Fahrt des Fahrzeugs im ungestörten Verkehr. Die Eignung von ARIMA-Modellen für die Nachbildung des freien Verkehrs auf der Basis stationärer Daten wurde unter anderem in BELZNER ET AL. (2003) gezeigt. Im Einklang mit der Definition aus Kapitel 3 wird Störung als ein Abweichen vom bisherigen Geschwindigkeitsverlauf, insbesondere als Geschwindigkeitsgefälle, angesehen. Um diese gezielt zu erkennen, werden, aufbauend auf dem entwickelten

ARIMA-Modell, zwei Modelle für die Detektion von Ausreißern und Unterschieden im Geschwindigkeitsniveau gebildet. Insgesamt gliedert sich die Störungserkennung in vier Module M1-M4 (siehe Abb. 5.2).

Neben der Störungserkennung besitzt SWIM einen Funktionsblock für das Fehlermanagement. Das Verfahren soll in der Praxis eingesetzt werden. Dabei muss beachtet werden, dass reale Daten häufig fehlerbehaftet sind oder teilweise ganz fehlen. Daher wird gefordert, dass der Algorithmus eine Art Fehlermanagement bereithält, um diese zu entdecken und nicht irrtümlich als Störung zu detektieren.

5.2. Einführung in die Zeitreihenanalyse

Dieser Abschnitt gibt eine kurze Einführung in die Zeitreihenanalyse und zeigt das allgemeine Vorgehen bei der Entwicklung eines ARIMA-Modells. Eine ausführliche Beschreibung findet sich in BOX UND JENKINS (1976).

Sinn der Zeitreihe ist es, eine Aussage über die Wahrscheinlichkeitsverteilung der Werte N_t zu einem Zeitpunkt t auf Basis der bereits vorliegenden Informationen N_{t-1}, \dots zu gewinnen. Grundsätzlich könnte die Beziehung $N_t = N_t(N_{t-1}, \dots)$ auch eine nichtlineare Form annehmen. ARIMA entspricht dem Sonderfall, bei dem eine lineare Beziehung unterstellt wird.

5.2.1. ARIMA-Modell

Definition 5.1 [Zeitreihe] Eine **Zeitreihe** ist eine nach einem Zeitindex geordnete Folge von Beobachtungen N_t einer genau definierten Variablen \mathcal{N}_t , mit $t = 1, \dots, m$.

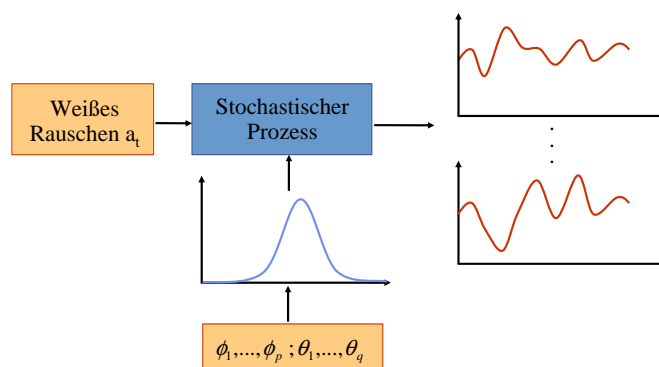


Abbildung 5.4.: Realisierung von Zufallsprozessen

In der modernen Zeitreihenanalyse wird eine Zeitreihe N_1, N_2, \dots, N_m von aufeinander folgenden Beobachtungen als Musterrealisierung einer unendlichen Population an solchen Zeitreihen angesehen, die von einem stochastischen Prozess erzeugt werden können (siehe Abb. 5.4). Diese

Art der Zeitreihenanalyse wurde vor allem durch BOX und JENKINS bekannt. Die von ihnen entwickelte Klasse der linearen, stochastischen ARIMA-Modelle basiert auf folgender Idee: „Eine Zeitreihe, deren aufeinander folgende Werte stark voneinander abhängig sind, wird durch eine Reihe unabhängiger „Stöße“ a_t produziert, die in einem linearen Filter in den Prozess N_t umgewandelt werden“ [BOX & JENKINS 1976]. Die Folge $a_t, a_{t-1}, a_{t-2} \dots$ wird üblicherweise als **weißes Rauschen** bezeichnet. Jeder Wert a_t stellt eine Stichprobe einer festen Verteilung dar. Voraussetzung für die Verwendung von ARIMA-Modellen ist, dass die a_t 's normalverteilt sind, den Erwartungswert $\mu_a = 0$ und die gleiche Varianz σ_a^2 besitzen.

Um eine allgemeine Betrachtung zu ermöglichen, ist es sinnvoll, den Rückhalteoperator B durch die Vorschrift

$$B \cdot N_t = N_{t-1}$$

zu definieren. Die p -fache Anwendung von B auf N_t wird als B^p bezeichnet und ergibt

$$B^p \cdot N_t = N_{t-p} \quad \text{bzw. für } a_t : \quad B^p \cdot a_t = a_{t-p}$$

Mit Hilfe dieses Operators ist es ferner möglich, Polynome der Form

$$\varphi(B) \cdot N_t = \phi(B) \cdot (1 - B)^d \cdot N_t = \theta(B) \cdot a_t$$

zu definieren. Diese werden allgemein als **autoregressiver integrierter moving-average Prozess (ARIMA (p, d, q))** bezeichnet.

Der autoregressive Operator $\phi(B)$ ist ein Polynom der Ordnung p .

$$\phi(B) = 1 - \phi_1 \cdot B - \dots - \phi_p \cdot B^p$$

Angewandt auf N_t stellt er eine gewichtete Summe vergangener Werte der Zeitreihe N_t dar.

$$\phi(B) \cdot N_t = N_t - \phi_1 \cdot N_{t-1} - \dots - \phi_p \cdot N_{t-p}$$

Analog ist der Operator $\theta(B)$ ein Polynom der Ordnung q .

$$\theta(B) = 1 - \theta_1 \cdot B - \dots - \theta_q \cdot B^q$$

$\theta(B) \cdot a_t$ enthält die Komponenten der gewichteten Summe oder den gleitenden Mittelwert vergangener Stöße a_t der Zeitreihe.

$$\theta(B) \cdot a_t = a_t - \theta_1 \cdot a_{t-1} - \dots - \theta_q \cdot a_{t-q}$$

Ein wichtiges Kriterium bei der Zeitreihenanalyse ist das der Stationarität, für die gilt, dass die Zeitreihenwerte um einen festen Mittelwert schwanken. In der Praxis zeigen jedoch viele

Zeitreihen ein nichtstationäres Verhalten. Durch d -fache Differenzenbildung kann ein Teil dieser Zeitreihen trend- und saisonbereinigt werden und danach schwache Stationarität aufweisen. Die d -fache Differenzierung wird als integrierende Komponente der Zeitreihe bezeichnet.

Im Verkehr gibt es in Wirklichkeit mehrere Zustände, die dem freien Verkehr zuzuordnen sind [KIM & KELLER 2001]. Es wird daher vermutet, dass auch der Verkehr nichtstationär ist. Die Zielsetzung liegt darin, diese Zustandswechsel von akuten Wechseln zu unterscheiden. Es wird angenommen, dass das nichtstationäre Verhalten im freien Verkehr durch Differenzenbildung beseitigt werden kann.

$$z_t = (1 - B)^d \cdot N_t$$

z_t bezeichnet die differenzierte Zeitreihe der Länge $n = m - d$.

Die Parameter $\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q$ dürfen nicht beliebige Werte annehmen, sondern müssen, um erforderliche Bedingungen einzuhalten, innerhalb bestimmter Intervalle liegen (siehe [BOX & JENKINS 1976]). Insbesondere müssen die Wurzeln des Polynoms $\phi(B) = 0$ außerhalb des Einheitskreises liegen, um Stationarität zu gewährleisten. Intuitiv hat dies die Bedeutung, dass sich die Zeitreihenwerte nicht explosionsartig mit der Zeit aufschwingen.

5.2.2. Modellbildung

Ziel der Modellbildung ist es, aus gegebenen Zeitreihen ein allgemeines Modell zu entwickeln, welches die Abhängigkeit der aufeinander folgenden Beobachtungen erkennt und deren Stochastik mit berücksichtigt. Dazu werden die Zeitreihen statistisch untersucht. Es wird versucht, von den Eigenheiten des Musters, d.h. der betrachtenden Zeitreihe, auf die der Population zu schließen. Die Population umfasst dabei alle möglichen Zeitreihen, die von dem stochastischen Prozess erzeugt werden können.

Ein ARIMA-Modell ist durch die Parameter $\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q, d$ und die Standardabweichung des weißen Rauschens σ_a festgelegt. Die Bestimmung erfolgt iterativ in drei Phasen (siehe Abb. 5.5):

1. Modell-Identifikation,
2. Iterative Schätzung der $p + q + 1$ Parameter und
3. Diagnostische Überprüfung des Modells.

Eine ausführlichere Beschreibung findet sich unter anderem in BELZNER (2002).

Die **Modell-Identifikation** dient der Bestimmung der Modell-Ordnung (p, d, q) und erfolgt anhand der Untersuchung von Autokorrelationen und partiellen Autokorrelationen der Zeitreihe und der Betrachtung ihrer Verläufe. Hohe Werte und ein langsames Abklingen der Autokorrelationsfunktion sind ein Hinweis darauf, dass ein Parameterwert an seiner Parametergrenze liegt und die Zeitreihe ein nichtstationäres Verhalten aufweist. Dies legt ein erneutes Differen-

zieren nahe. Weiter geben die charakteristischen Verläufe der Funktionen, etwa das Abklingen der Korrelationen, Aufschluss über die Parameter p und q .

Basierend auf den, bei der Modell-Identifikation gewählten Modell-Ordnungen und Anfangsschätzwerten $\phi_i, i \in \{1, \dots, p\}$, und $\theta_j, j \in \{1, \dots, q\}$, werden bei der **Parameterschätzung** mit Hilfe der Maximum-Likelihood-Funktion effizientere Schätzungen gebildet.

Das Modell mit den gewählten Parametern wird schließlich an einem unabhängigen Datensatz auf seine Güte untersucht. Ein wichtiger Aspekt der **diagnostischen Überprüfung** ist die Analyse der Residuen a_t . Der Begriff **Residuum** bezeichnet den übrig gebliebenen Rest zwischen dem Wert N_t der realen Zeitreihe und der Näherung durch das Modell. Bildet das ARIMA-Modell den stochastischen Prozess gut nach, sollten sich die Schätzungen der a_t 's dem weißen Rauschen annähern und demzufolge unkorreliert sein. Weiter kann ein Test mit einem erweiterten Modell Aufschluss auf eine Übertrainiertheit, also eine zu starke Anpassung an die Musterzeitreihe, des Modells geben.

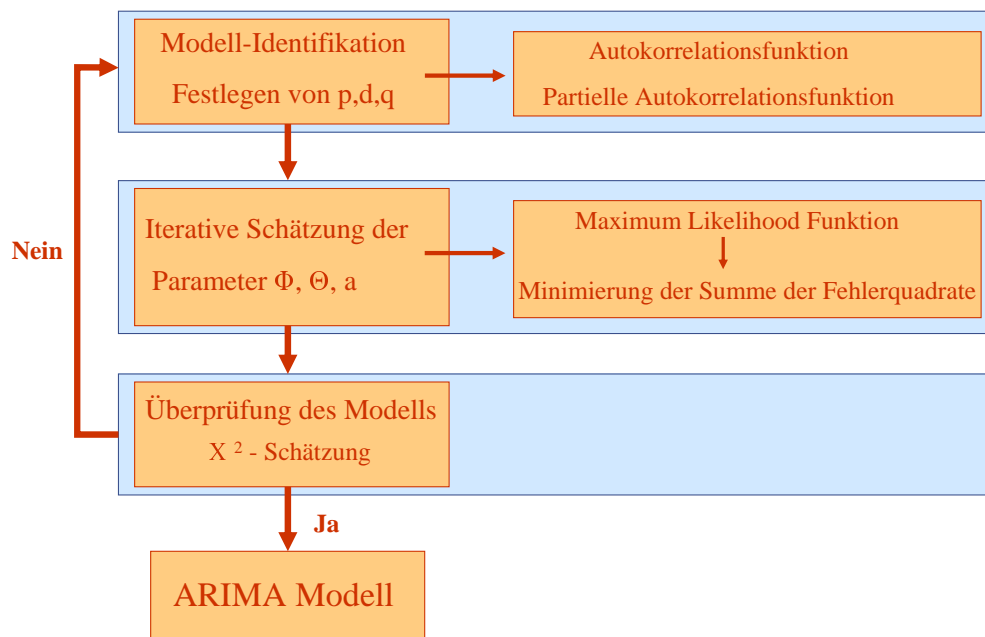


Abbildung 5.5.: Allgemeine Modellentwicklung eines ARIMA-Modells

5.3. ARIMA-Modell für den ungestörten Verkehr

Die Fahrt eines Fahrzeugs im freien Verkehr wird mit Hilfe eines univariaten ARIMA-Modells nachgebildet. Als Kenngröße wird die Geschwindigkeit des Fahrzeugs gewählt. Die Geschwindigkeitsdaten stehen äquidistant im Sekundentakt an den Fahrzeugbussen zur Verfügung. Die Modellentwicklung wird unter Nutzung der MATLAB Toolbox GARCH anhand von simulierten Daten durchgeführt.

5.3.1. Entwicklungsszenario

Als Simulationsstrecke für das Entwicklungsszenario wurde der ehemalige Streckenabschnitt der A92 zwischen Anschlussstelle Flughafen München und Autobahnkreuz Neufahrn gewählt. Diese unterscheidet sich von der Strecke des Evaluationsszenarios und soll die Übertragbarkeit des zu entwickelnden Modells gewährleisten. Die Länge der dreispurigen Simulationsstrecke beträgt 10km, die Simulationszeit eine Stunde. Um für die Modellierung des ungestörten Verkehrs mögliche Engpässe zu vermeiden, werden reale Auf- und Abfahrten in diesem Zusammenhang nicht betrachtet.

Die Strecke wird im Endlosband simuliert. Das bedeutet, dass die Fahrzeuge mit unveränderten Zustandsgrößen am Anfang der Strecke wieder eingesetzt werden. Es wird also eine Art Ring simuliert, der den Vorteil hat, dass keine Lücken und Unstetigkeiten im Geschwindigkeitsverlauf der einzelnen Fahrzeugtrajektorien auftreten.



Abbildung 5.6.: Streckenverlauf der A92 vor dem Jahr 2003

Es werden drei verschiedene Szenarien mit 250 Fahrzeugen über 3600 Sekunden simuliert (siehe Tabelle 5.1). Wie bereits in Abschnitt 3.2.1 erwähnt, zeigt jedes Fahrzeug und jeder Fahrer charakteristische Eigenschaften. So könnte es sein, dass jeder Fahrer ein eigenes Modell benötigt. Zur Untersuchung der Hypothese, ob die Form des ARIMA-Modells von den Eigenschaften eines Fahrers abhängt, wird in Szenario 1 ein Einheitsfahrzeug, ein Mittelklassefahrzeug, mit unterschiedlichen Fahrern simuliert. Die Fahrerdatei besteht aus 100 verschiedenen Fahrern, deren Eigenschaften gaußverteilt sind und die zufällig auf die Fahrzeuge aufgeteilt werden. Im zweiten Szenario werden zusätzlich unterschiedliche Fahrzeuge automatisch gaußverteilt erzeugt. Dieser Fall bildet den Regelfall nach. Das dritte Szenario verwendet dagegen einen durchschnittlichen Fahrertyp mit den Fahrzeugen des zweiten Szenarios.

Für die Analyse jedes Szenarios werden zufällig 30 Fahrzeuge ausgewählt und ihre Zeitreihen untersucht. Die Verkehrsstärke wird so gewählt, dass noch freier Verkehr herrscht, aber schon

Wechselwirkungen zwischen Fahrzeugen auftreten. Die durchschnittliche Geschwindigkeit und ihre Standardabweichung zeigt Tabelle 5.1.

Szenario	Anzahl Fahrzeuge	Anzahl Fahrer	Mittelwert	Standardabweichung
1	1 Fahrzeug	mehrere Fahrer	$139 \frac{km}{h}$	$17 \frac{km}{h}$
2	mehrere Fahrzeuge	mehrere Fahrer	$104 \frac{km}{h}$	$20 \frac{km}{h}$
3	mehrere Fahrzeuge	ein Fahrer	$115 \frac{km}{h}$	$10 \frac{km}{h}$

Tabelle 5.1.: Entwicklungsszenarien für das ARIMA-Modell des ungestörten Verkehrs

5.3.2. Modellidentifikation

Wie in Abschnitt 5.2 erklärt wurde, müssen im ARIMA-Modell die Varianzen konstant sein. Für die Geschwindigkeit im Verkehr ist das nicht der Fall. Diese Eigenschaft bezeichnet man als **heteroskedastisch**. Sie hat zur Folge, dass die Varianzen von der Geschwindigkeit abhängen. Daher sind die Annahmen für ein ARIMA-Modell verletzt. Aus Untersuchungen geht jedoch hervor, dass eine Transformation mit dem Logarithmus die Eigenschaft hat, dass die Stöße annähernd homoskedastisch sein könnten. Aus diesem Grund wird in dieser Arbeit eine logarithmische Transformation der Geschwindigkeiten auf ein Intervall zwischen $[0, 1]$ durchgeführt. Sie soll auftretende große Differenzen homogenisieren, indem große Geschwindigkeitswerte stärker gesenkt werden. Die Korrelationen werden dann mit den transformierten Geschwindigkeitszeitreihen berechnet.

Vorerst geht es darum, ein Modell für den ungestörten Fahrtverlauf zu entwickeln. Für die Analyse des Fahrtverlaufs im ungestörten Verkehr ist insbesondere der beeinflusste und synchronisierte Verkehr und weniger der vollkommen freie Verkehr von Interesse. Dort sind die Zeitreihenwerte allein von dem Fahrer und seiner Wunschgeschwindigkeit abhängig.

Es ist zielführend, die freien Geschwindigkeiten auf Werte um 0 zu transformieren. Daher wird als Basis der logarithmischen Transformation die Wunschgeschwindigkeit $v_f + 1$ gewählt und diese anschließend gespiegelt.

$$\tilde{v}_t = 1 - \log_{(v_f+1)}(v_t + 1)$$

v_f : Wunschgeschwindigkeit des Fahrers i

v_t : Geschwindigkeit zum Zeitpunkt t

Die Wunschgeschwindigkeit ergibt sich in der Simulation aus den Eigenschaften des Fahrers. Durch die logarithmische Transformation wird die Geschwindigkeit so transformiert, dass die Wunschgeschwindigkeit keinen Einfluss auf die Modellierung und die Darstellung von SWIM

hat. Untersuchungen haben gezeigt, dass die Annahme einer einheitlichen Wunschgeschwindigkeit zu keiner großen Verletzung der homoskedastischen Voraussetzung führt. In der Realität wird die Wunschgeschwindigkeit in der Regel zu $v_f = 120$ gesetzt.

Zur Aufbereitung der Zeitreihe als Eingangsgröße der Berechnungen mit der MATLAB Toolbox werden die transformierten Zeitreihen \tilde{v}_t mittelwertbereinigt.

$$N_t = \tilde{v}_t - \langle \tilde{v} \rangle$$

Dabei stellt $\langle \tilde{v} \rangle$ den Mittelwert von \tilde{v}_t über $t = 1, \dots, m$ dar.

Die Autokorrelationen und partiellen Autokorrelationen werden für die transformierten Fahrzeugzeitreihen von Szenario 1 und 2 für $d = 0, 1, 2$ berechnet. Um zu berücksichtigen, dass es sich bei den berechneten Korrelationen um Schätzungen handelt, deren Varianzen sehr groß sein können, werden zusätzlich die Standardabweichungen betrachtet. Daraus gehen einige mögliche Modelle (p, d, q) hervor, die bei der Parameterschätzung näher untersucht werden. Sie sind in Tabelle 5.2 dargestellt. Ein statistischer Hypothesentest bestätigt das Vorhandensein von Korrelationen in der Zeitreihe und damit den Zusammenhang der Zeitreihenwerte N_t von den vergangenen Werten N_{t-1}, \dots . Die Verwendung eines ARIMA-Modells ist daher gerechtfertigt.

d	Modell	
$d = 1$	(1,1,0)	$N_t = (1 + \phi) \cdot N_{t-1} - \phi \cdot N_{t-2} + a_t$
	(1,1,1)	$N_t = (1 + \phi) \cdot N_{t-1} - \phi \cdot N_{t-2} + a_t - \theta \cdot a_{t-1}$
	(0,1,1)	$N_t = N_{t-1} + a_t - \theta \cdot a_{t-1}$
$d = 2$	(1,1,2)	$N_t = (1 + \phi) \cdot N_{t-1} - \phi \cdot N_{t-2} + a_t - \theta_1 \cdot a_{t-1} - \theta_2 \cdot a_{t-2}$
	(0,2,1)	$N_t = 2 \cdot N_{t-1} - N_{t-2} + a_t - \theta \cdot a_{t-1}$
	(0,2,2)	$N_t = 2 \cdot N_{t-1} - N_{t-2} + a_t - \theta \cdot a_{t-1} - \theta_2 \cdot a_{t-2}$

Tabelle 5.2.: Modellvorschläge für das ARIMA-Modell nach der Modellidentifikation

5.3.3. Parameterschätzung und diagnostische Überprüfung

Die ausgewählten Kandidatenmodelle werden im Folgenden näher untersucht und eine Schätzung der Parameter durchgeführt. Dazu werden die transformierten Geschwindigkeitszeitreihen der schon in der Modellidentifikation gewählten Fahrzeuge verwendet. Die Koeffizienten $\phi_i, i \in \{1, \dots, p\}$, und $\theta_j, j \in \{1, \dots, q\}$ werden mit Hilfe der Maximum-Likelihood-Methode iterativ geschätzt.


Unter der Annahme der Normalverteilung für die Residuen a_t und großen Zeitreihen genügt es, statt der Maximum-Likelihood-Funktion, die Quadratsummenfunktion $S(\phi, \theta)$ zu berechnen und zu minimieren [BOX & JENKINS 1976]. Bei Bestimmung der bedingten Quadratsummen-

funktion in Abhängigkeit der Vektoren der Anfangswerte \vec{z}_0 und \vec{a}_0 von z_t und a_t hat $S(\phi, \theta)$ folgende Form:


$$S(\phi, \theta) = \sum_{t=1}^n a_t^2(\phi, \theta | \vec{z}_0, \vec{a}_0, \vec{z}) \quad (5.1)$$

mit $z_t = (1 - B)^d N_t$ und $n = m - d$


Nach abgeschlossener Parameterschätzung werden vier Tests durchgeführt, die zeigen sollen, wie gut jedes Modell (p, d, q) und seine Parameter die Geschwindigkeitszeitreihen nachbilden. Bei zwei der Tests handelt es sich um die Berechnung der mittleren quadratischen und der mittleren absoluten Fehler bei der Prognose der Geschwindigkeit für einen Zeitschritt. Der dabei gemachte Prognosefehler entspricht, wie in Abschnitt 5.2.2 angegeben, den Residuen a_t der Zeitreihe. Er wird nach Rücktransformation als Differenz zwischen vorhergesagter und tatsächlicher Geschwindigkeit angegeben. Zur weiteren Überprüfung der ARIMA-Modelle werden zwei χ^2 -verteilte Hypothesentests durchgeführt. Der Ljung Box Test testet auf Autokorrelationen innerhalb von Zeitreihen während der Likelihood Ratio Test überprüft, ob die Hinzunahme eines weiteren Parameters zu einer signifikanten Verbesserung des Modells führt. Das Signifikanzniveau wird für beide Tests auf $\alpha = 0.05$ gesetzt.




(a) Mittlerer absoluter Fehler



(b) Mittlerer quadratischer Fehler



(c) Ljung Box Test



(d) L-Ratio Testgröße der Modelle (1, 1, 1) und (1, 1, 0)

Abbildung 5.7.: Ergebnis der Parameterschätzung für Szenario 1

Die Ergebnisse der einzelnen Modelle für Szenario 1 sind in Abbildung 5.7 grafisch dargestellt. Deutlich zu sehen ist, dass die Modelle (0, 2, 1) und (0, 1, 1) im Vergleich zu den anderen Model-

len bei jedem betrachteten Fahrzeug höhere χ^2 -Werte für den Ljung Box Test aufweisen (siehe Abb. 5.7(c)). Dies ist ein Hinweis auf Autokorrelationen in den Residuen und deutet darauf hin, dass beide Modelle nicht adäquat sind. Modell (0, 1, 1) weist zudem immer die höchsten mittleren Fehler auf (siehe Abb. 5.7(a) und 5.7(b)). Der Likelihood Ratio Test vergleicht die Modelle (1, 1, 1) und (1, 1, 0). Abbildung 5.7(d) zeigt die Werte der Testgröße. Bis auf einen Wert liegen alle Werte der Testgröße oberhalb des kritischen Wertes. Das hat zur Folge, dass das restringierte Modell (1, 1, 0) mit einer Ausnahme für alle Fahrzeuge auf dem Signifikanzniveau α abgelehnt wird.

Es ist zu vermuten, dass der Ruck, und damit die Geschwindigkeit, mit denen das Gas- bzw. Bremspedal getreten wird, von Bedeutung ist. Der Ruck entspricht dabei der Differenzierung $d = 2$ von N_t . Jedoch können auch kleinere Differenzen ($d < 2$) den Ruck modellieren, wenn dafür zusätzliche autoregressive Parameter vorhanden sind. Die Modelle (0, 2, 2) und (1, 1, 2) sind daher von der Ordnung gleichwertig. Ein direkter Vergleich der beiden Modelle zeigt für alle Fahrzeuge kleinere Prognosefehler sowie kleinere Werte der Ljung Box Testgröße für Modell (1, 1, 2). Aus diesem Grund wird Modell (0, 2, 2) ebenfalls verworfen.

In Szenario 1 wurden unterschiedliche Fahrer betrachtet. Zusammengefasst zeigen die Modelle (1, 1, 1) und (1, 1, 2) bei allen Fahrzeugen die beste Modellierung des Geschwindigkeitsverlaufs. Das deutet darauf hin, dass es gerechtfertigt ist, ein gemeinsames Modell für unterschiedliche Fahrertypen zu verwenden. Tabelle 5.3 zeigt die maximale Differenz der Parameter $\phi_i, i \in \{1, \dots, p\}$, und $\theta_j, j \in \{1, \dots, q\}$ zwischen den einzelnen Fahrzeugen.

Modell	Maximale Differenz
(1, 1, 1)	$\Delta\phi = 0.12$
	$\Delta\theta = 0.23$
(1, 1, 2)	$\Delta\phi = 0.16$
	$\Delta\theta_1 = 0.33$
	$\Delta\theta_2 = 0.15$

Tabelle 5.3.: Maximale Parameterdifferenz bei unterschiedlichen Fahrern und einheitlichem Fahrzeug

In Szenario 2 wird der Regelfall betrachtet. Die Fahrer werden dazu auf unterschiedliche Fahrzeuge aufgeteilt. Auch hier weisen die Modelle (0, 2, 1) und (0, 1, 1) hohe χ^2 -Werte und höhere Werte der mittleren Fehler auf. Die Ausnahme bildet ein Motorrad, dessen Parameterwerte sich deutlich von denen der anderen Fahrzeugklassen unterscheiden. Die Ergebnisse des Likelihood-Ratio-Tests zeigen wie bei Szenario 1 eine schlechtere Darstellung von Modell (1, 1, 0) gegenüber (1, 1, 1). Dies gilt auch für Modell (0, 2, 2) gegenüber Modell (1, 1, 2), so dass wie bei Szenario 1 die Modelle (1, 1, 1) und (1, 1, 2) gewählt werden. Die durchgeführten diagnostischen Tests für die die Szenarien 1 und 2 mit einer veränderten Fahrzeugaufstellung neu simuliert wurden, bestätigen die getroffene Auswahl.

Zur weiteren Überprüfung wird eine Parameterschätzung der Modelle (1, 1, 1) und (1, 1, 2) für Szenario 3 durchgeführt. Diese bestätigt die Ergebnisse der Szenarien 1 und 2. Auch hier ist das Modellierungsverhalten beider Modelle ähnlich. Zudem zeigt sich, dass das Motorrad auch bei identischem Fahrer ein anderes Modellierungsverhalten aufweist, welches auch dem Fahrverhalten in der Realität entspricht. Dasselbe gilt für Lastkraftwagen.

Im Folgenden werden die geschätzten ARIMA-Parameter der einzelnen Personenkraftwagen zu Mittelwerten aggregiert (siehe Tabelle 5.4). Lastkraftwagen und Motorräder werden aufgrund der Ergebnisse von Szenario 2 und deren Bestätigung in Szenario 3 ausgeschlossen.

Szenario	Modell	Parameter		
		ϕ	θ	θ_2
Szenario 1	(1, 1, 1)	$\phi = 0.66$	$\theta = -0.19$	
	(1, 1, 2)	$\phi = 0.72$	$\theta_1 = -0.25$	$\theta_2 = -0.06$
Szenario 2	(1, 1, 1)	$\phi = 0.6$	$\theta = -0.07$	
	(1, 1, 2)	$\phi = 0.62$	$\theta_1 = -0.09$	$\theta_2 = -0.02$

Tabelle 5.4.: Mittelwerte der Parameter nach der Parameterschätzung




Abbildung 5.8.: Vergleich der Prognosefehler der Modelle (1, 1, 1) und (1, 1, 2)

Die Überprüfung der resultierenden vier Modelle erfolgt anhand eines Testszenarios, für das Szenario 2 mit veränderter Fahrzeugaufstellung neu simuliert wird. Die mittleren absoluten und quadratischen Prognosefehler werden berechnet. Abbildung 5.8 stellt die Ergebnisse für die Modelle der Szenarien 1 und 2 dar. Die blauen Balken geben die Ergebnisse für die ARIMA-Modelle (1, 1, 1) an während die gelben die Ergebnisse der Modelle (1, 1, 2) darstellen. Bei beiden Modellen zeigt sich, dass das ARIMA-Modell (1, 1, 2) gegenüber dem (1, 1, 1)-Modell einen vergleichbaren mittleren absoluten Fehler besitzt während der mittlere quadratische Fehler jeweils größer ist. Zudem wird bei genauerer Betrachtung der Parameterwerte θ_2 ersichtlich, diese sehr klein sind (siehe Tabelle 5.4). Aus diesem Grund wird Modell (1, 1, 1) bevorzugt.

Für die Wahl der Parameter des ARIMA-Modells $(1, 1, 1)$ werden die Fehler aller Fahrzeuge getrennt nach Fahrzeugklassen berechnet. Dabei zeigt sich, dass für die Parameter des Szenarios 1 die mittleren absoluten Fehler für alle Fahrzeugklassen kleiner sind. Dies gilt auch für die mittleren quadratischen Fehler mit Ausnahme der Klasse 1, die die Motorräder repräsentiert. Als zusätzliches Maß wird die Standardabweichung der Parameter der einzelnen Fahrzeuge berechnet (siehe Tabelle 5.5). Es zeigt sich, dass die Parameter des Szenarios 1 homogener ausfallen.

Standardabweichung	ϕ	θ
Parameter Szenario 1	$\sigma_\phi = 0.026$	$\sigma_\theta = 0.05$
Parameter Szenario 2	$\sigma_\phi = 0.04$	$\sigma_\theta = 0.53$

Tabelle 5.5.: Standardabweichung der Parameter

Aus diesem Grund wird für die Modellierung des ungestörten Verkehrs ein ARIMA-Modell der Form $(1, 1, 1)$ mit Parametern $\phi = 0.66$ und $\theta = -0.19$ gewählt.

5.4. Interventionsanalyse

In Abschnitt 5.3 wurde ein ARIMA-Modell zur Modellierung von ungestörtem Verkehr entwickelt. Der folgende Abschnitt beschäftigt sich mit der Modellierung von gestörtem Verkehr. Das Auftreten einer Störung wird in der Geschwindigkeitsganglinie durch einen Geschwindigkeitsabfall deutlich, bei dem sich das Geschwindigkeitsniveau ändert. Für die Störungserkennung wird nun versucht, den Verlauf der Störung mit Hilfe zweier Modelle nachzubilden. Dann wird überprüft, ob es Anhaltspunkte für eine Wirkung der Störung, speziell einer Veränderung im Verlauf der betrachteten Zeitreihe, gibt. Dieses Vorgehen wird in der Literatur als **Interventionsanalyse** bezeichnet.

Die beiden nachfolgend vorgestellten Modelle bilden die Module M1 und M2 innerhalb von SWIM. Sie haben die Funktion der

- Erkennung von Änderungen im Geschwindigkeitsniveau (Modul M1) und der
- Erkennung von Ausreißern und starken Geschwindigkeitsgefällen (Modul M2).

5.4.1. Erkennung von Änderungen im Geschwindigkeitsniveau – M1

Mit Hilfe des ersten Modells wird versucht, eine Änderung im Geschwindigkeitsniveau zu erkennen, die zu einem bekannten Zeitpunkt T eintritt und bestehen bleibt. Dazu wird das Auftreten der Störung als externes Ereignis angesehen, das die verrauschte Zeitreihe des freien Verkehrs überlagert (siehe Abb. 5.9). Die Störungserkennung wird als statistischer Test formuliert:

Der ungestörte Verkehr dient hierbei als „Nullhypothese“. Zur Bildung einer Alternativhypothese wird das Modell herangezogen. Dazu wird die Störung und ihr Verlauf mit Hilfe eines sog. **Transfer-ARIMA-Modells** nach BOX UND JENKINS (1976) modelliert. Als Hypothese wird überprüft, ob sich das Ereignis auf eine betrachtete Zeitreihe Y_t auswirkt.

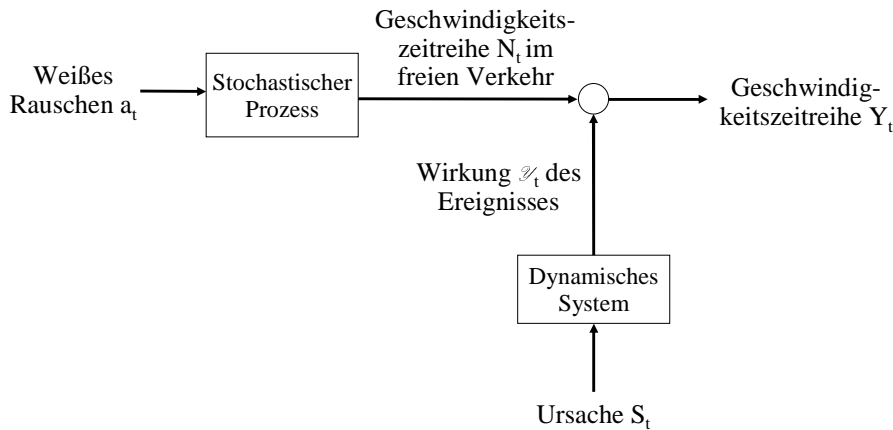


Abbildung 5.9.: Modell der Geschwindigkeitszeitreihe bei Niveauänderung

Allgemein hat ein Transfer-ARIMA-Modell folgende Form [BOX ET AL. 1994]:

$$Y_t = \mathcal{Y}_t + N_t \quad (5.2)$$

In diesem Zusammenhang stellt Y_t die resultierende Geschwindigkeitszeitreihe dar. Sie setzt sich zusammen aus der Zeitreihe \mathcal{Y}_t , die die Wirkung des hypothetischen externen Ereignisses darstellt, und der Geschwindigkeitszeitreihe der ungestörten Fahrt N_t . N_t ist nach Abschnitt 5.3 ein ARIMA-Modell der Form (1, 1, 1):

$$(1 - \phi B)(1 - B) \cdot N_t = (1 - \theta B) \cdot a_t \quad (5.3)$$

Die Ursache einer Störung kann man sich abstrakt als eine Sprungfunktion $S_t^{(T)}$ vorstellen, die zu einem Zeitpunkt T eintritt und die Geschwindigkeitszeitreihe auf ein anderes Niveau zwingt (siehe Abb. 5.10):

$$S_t^{(T)} = \begin{cases} 0, & t < T, \\ 1, & t \geq T. \end{cases}$$

Das Niveau der Zeitreihe ändert sich dabei nachhaltig ab dem Zeitpunkt $T + 1$ um einen Wert ω_1 . \mathcal{Y}_t hat damit folgende Form:

$$\mathcal{Y}_t = \omega_1 \cdot B \cdot S_t^{(T)} \quad (5.4)$$

Aufgrund der Überlagerung der beiden Zeitreihen ändert sich nur das Niveau der Zeitreihe N_t , nicht aber die inneren Zusammenhänge.

Im Folgenden wird die Prozedur beschrieben, die notwendig ist, um den Parameter ω_1 der Ereignisfunktion \mathcal{Y}_t zu schätzen und die Wahrscheinlichkeit dafür anzugeben, ob die Änderung der Zeitreihe das Ergebnis externer abrupter Ereignisse war. Dabei wird die Schätzung des Parameters nicht mit klassischen Methoden der Regelungstechnik durchgeführt. Diese Verfahren sind häufig bei verrauschten Prozessen, wie es hier der Fall, nicht erfolgreich [BOX & JENKINS 1976]. Stattdessen wird die Schätzung mit Hilfe der Maximum-Likelihoodfunktion durchgeführt.




Abbildung 5.10.: Modellierung einer Störung mit Sprungfunktion

Parameterschätzung von ω_1

Durch Umformung von Gleichung 5.2 mit 5.3 und 5.4 erhält man:

$$w_t = \omega_1 \cdot x_t + a_t$$

mit

$$\begin{aligned} w_t &= (1 - \theta B)^{-1} \cdot (1 - \phi B) \cdot (1 - B) \cdot Y_t \\ &= Y_t + (\theta - \phi - 1) \cdot Y_{t-1} + (1 - \theta) \cdot (\phi - \theta) \cdot \sum_{s=0}^{\infty} \theta^s \cdot Y_{t-2-s} \\ x_t &= (1 - \theta B)^{-1} \cdot (1 - \phi B) \cdot (1 - B) \cdot B \cdot S_t^{(T)} \\ &= \begin{cases} 0, & t \leq T; \\ 1, & t = T + 1; \\ (\theta - \phi) \cdot \theta^{t-T-2}, & t \geq T + 2. \end{cases} \end{aligned}$$

Für a_t gilt somit:

$$a_t = w_t - \omega_1 \cdot x_t$$

Analog zu der Parameterschätzung der Parameter ϕ und θ wird ω_1 geschätzt, indem die Quadratsummenfunktion

$$S(\omega_1, \phi, \theta) = \sum_{t=1}^n a_t^2(\omega_1 | \phi, \theta, \vec{x}_0, \vec{y}_0, \vec{a}_0)$$

bezüglich ω_1 minimiert wird (siehe auch Abschnitt 5.3). Die Vektoren $\vec{x}_0, \vec{y}_0, \vec{a}_0$ bezeichnen dabei die Startwerte für die Minimierung.

Der Maximum-Likelihood-Schätzer $\widehat{\omega}$ von ω ergibt sich mit

$$a_t^2 = (w_t - \omega_1 \cdot x_t)^2 \Rightarrow S(\omega_1, \phi, \theta) = \sum_{t=1}^n (w_t - \omega_1 \cdot x_t)^2$$

und

$$\sum_{t=1}^n \frac{da_t^2}{d\omega_1} = \sum_{t=1}^n 2 \cdot (w_t - \omega_1 \cdot x_t) \cdot (-x_t) \equiv 0$$

zu:

$$\widehat{\omega}_1 = \frac{\sum_{t=1}^n x_t \cdot w_t}{\sum_{t=1}^n x_t^2}$$

Da $\sum_{t=1}^n x_t \cdot w_t$ die Varianz σ_a^2 besitzt, gilt für die Varianz von $\widehat{\omega}_1$:

$$\sigma_{\widehat{\omega}_1}^2 = \frac{\sigma_a^2}{\sum_{t=1}^n x_t^2}$$

Ein Signifikanztest dient dazu, herauszufinden, ob es sich bei einer Abweichung zum Zeitpunkt T wirklich um eine Niveauänderung handelt ($\omega_1 \neq 0$) oder ob die Nullhypothese $\omega_1 = 0$ gerechtfertigt ist. Dazu wird die Schätzung ω_1 mit der Standardabweichung der Zeitreihe verglichen. Die Testgröße λ ergibt sich damit zu

$$\lambda = \frac{\widehat{\omega}_1}{\sigma_{\widehat{\omega}_1}}$$

Eine Störung gilt als erkannt, wenn λ einen Schwellenwert λ_{grenz} übertrifft ($|\lambda| > \lambda_{grenz}$). Für die Erkennung einer Niveauänderung wird $\lambda_{grenz} = 3.0$ gesetzt. Dies entspricht unter Annahme der Normalverteilung einer statistischen Sicherheit von 99.7%, d.h. Fehler 1.Art werden für 3 Promille in Kauf genommen.

Bisher wurde vorausgesetzt, dass ein externes Ereignis zu einem bekannten Zeitpunkt T eintritt. Die Hypothese wird überprüft, ob sich das Ereignis zu einer Störung entwickelt. Bei Verkehrsstörungen ist jedoch der Eintritt einer Störung nicht bekannt. Prinzipiell müssten zu jedem betrachteten Zeitpunkt t alle potentiellen Eintrittszeitpunkte $T_i, i \in \{1, \dots, n\}$, der Störung untersucht werden. Aufgrund von Rechenzeitbeschränkungen im Echtzeitbetrieb sollen nur zwei mögliche Zeitpunkte T_1 und T_2 in SWIM betrachtet werden. Bei der Festlegung der beiden Zeitpunkte stellte sich heraus, dass die Empfindlichkeit der Schätzung, d.h. ob eine Ni-

veauänderung erkannt wird, in hohem Maße von dem Verhältnis zwischen der Länge der betrachteten Zeitreihe n und dem Zeitpunkt der Störung T abhängig ist. Bei der Analyse mit realen XFCD-Fahrten zeigte sich, dass, um starke Niveauänderungen innerhalb eines kurzen Zeitintervalls zu erkennen, das Verhältnis n/T klein sein sollte (siehe Abb. 5.10). Weiter darf die Länge der betrachteten Zeitreihe n nicht zu klein gewählt werden, da auf ihrer Basis die Standardabweichung σ_a berechnet wird. Die Parameter sind am Ende von Kapitel 6 dargestellt.

5.4.2. Erkennung von Ausreißern und starken Geschwindigkeitsgefällen – M2

Das oben entwickelte Modell erkennt Unterschiede im Geschwindigkeitsniveau. Zusätzlich wird ein weiteres Modell verwendet, das speziell Ausreißer und starke Geschwindigkeitsgefälle detektiert. Anwendungen in der Praxis haben in der Regel mit fehlerhaften oder fehlenden Daten zu kämpfen. Diese sog. Ausreißer sollen nicht fälschlicherweise als Störung detektiert werden. Neben der Erkennung von einzelnen Ausreißern, wie sie bei durchgeführten XFCD-Testfahrten auftraten, dient das Modell dazu, starke Geschwindigkeitsabstiege schnell aufzudecken.

Abstrakt kann man sich einen fehlerhaften Wert als einen zusätzlichen Stör-Stoß $\omega_2 \cdot P_t^{(T)}$ mit

$$P_t^{(T)} = \begin{cases} 0, & t \neq T, \\ 1, & t = T. \end{cases}$$

vorstellen, der die Fahrt eines Fahrzeugs zu einem Zeitpunkt T stört (siehe Abb. 5.11). Dabei kann es sich zum Beispiel um ein plötzlich erzwungenes Abbremsmanöver handeln. Dieses Ereignis beeinflusst vorübergehend auch die nachfolgenden Werte der Zeitreihe N_{T+1}, N_{T+2}, \dots .




Abbildung 5.11.: Modell der Geschwindigkeitszeitreihe bei Ausreißern

Der zusätzliche Stoß auf die Zeitreihe $(1 - \phi B) \cdot (1 - B) \cdot Y_t = (1 - \theta B) \cdot a_t$ kann folgendermaßen dargestellt werden:

$$(1 - \phi B) \cdot (1 - B) \cdot Y_t = (1 - \theta B) \cdot (\omega_2 \cdot P_t^{(T)} + a_t)$$

beziehungsweise

$$(1 - \theta B)^{-1} \cdot (1 - \phi B) \cdot (1 - B) \cdot Y_t = \omega_2 \cdot P_t^{(T)} + a_t$$

Mit $e_t = (1 - \theta B)^{-1} \cdot (1 - \phi B) \cdot (1 - B) \cdot Y_t$ gilt für die Quadratsummenfunktion $S(\omega_2, \phi, \theta)$

$$\sum_{t=1}^n a_t^2 = \sum_{t=1}^n (e_t - \omega_2 \cdot P_t^{(T)})^2$$

Nach Minimierung der kleinsten Fehlerquadrate folgt als Maximum-Likelihood-Schätzer von ω_2 :

$$\widehat{\omega}_2 = e_T = \theta \cdot e_{T-1} + Y_T - (1 + \phi) \cdot Y_{T-1} + \phi \cdot Y_{T-2}$$

Der Parameter ω_2 lässt sich somit einfach durch der Wert e_T zum Zeitpunkt T der Störung schätzen. Die Varianz ω_2 ergibt sich zu:

$$\sigma_{\widehat{\omega}_2}^2 = \sigma_a^2$$

Da im ungestörten Verkehr $a_t = e_t$ gilt, kann die Varianz der Residuen über

$$\sigma_a^2 = \frac{1}{n} \cdot \sum_{t=1}^n e_t^2$$

geschätzt werden. Die Testgröße λ ergibt sich für dieses Modell zu:

$$\lambda = \frac{e_T}{\sigma_a}$$

Als Schwellenwert wird $\lambda_{\text{grenz}} = 3.5$ gesetzt. Dies entspricht einer statistischen Sicherheit von 99.96%.

5.5. Aufbau und Funktionsweise von SWIM

Der entwickelte Algorithmus SWIM beschäftigt sich ausschließlich mit der Erkennung von Staueinfahrten und Stauausfahrten sowie instabilen Bereichen auf Autobahnen. Die Entwicklung erfolgt anhand der in Abschnitt 6.3.2 dargestellten Lernszenarien.

Abbildung 5.12 zeigt die in SWIM abgebildeten Module. Das Verfahren kann in zwei große Funktionsblöcke unterteilt werden, den Bereich des Fehlermanagements und den Bereich der Störungserkennung. Um Ausreißer in den Daten zu erkennen wird das stochastische Ausreißermodell M2 verwendet und überprüft, ob der Geschwindigkeitsgradient zweier aufeinander folgender Zeitschritte eine Richtungsänderung erfährt.

Die in Abschnitt 5.4 hergeleiteten Modelle dienen zur Erkennung von Änderungen im Geschwindigkeitsniveau (Modul M1) sowie von starken Geschwindigkeitsgefällen (Modul M2). Sie bilden den Kern der Störungserkennung innerhalb des Verfahrens SWIM. Zusätzlich zu den oben dargestellten Modellen werden noch weitere Kriterien eingeführt, damit eine Störung auch

als solche erkannt wird. Eine Änderung im Geschwindigkeitsniveau kann auch zwischen hohen Geschwindigkeiten auftreten. Die Detektion soll nur für solche Störungen erfolgen, deren Geschwindigkeit auf ein tiefes Geschwindigkeitsniveau fällt und deren Geschwindigkeitsgefälle eine Gefahr für nachfolgende Fahrzeuge darstellt. Aus diesem Grund wird gefordert, dass eine bestimmte Geschwindigkeitsdifferenz $\Delta v > v_{\Delta}$ innerhalb eines Zeitintervalls ΔT herrschen muss (Modul M3). Das bedeutet, dass eine Verzögerung a von mindestens $a = \frac{v_{\Delta}}{\Delta T}$ auftritt. Zusätzlich werden die Verzögerungen a in einem sehr kurzen Zeitintervall ΔT_a berechnet (Modul M4). Diese sollen Gefahren erkennen, bei denen es zu besonders starken Geschwindigkeitsgefällen kommt.

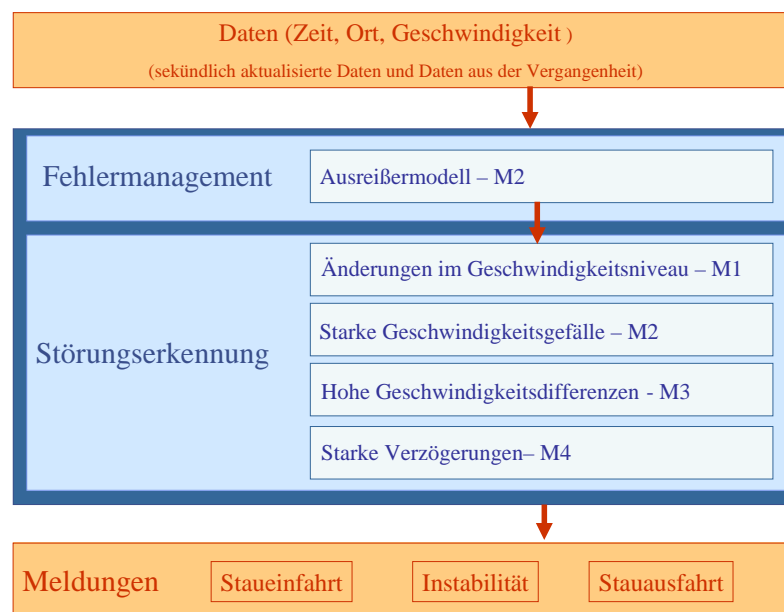


Abbildung 5.12.: Struktur von SWIM

SWIM unterscheidet intern die Zustände frei, instabil und gestört. Eine Meldung wird jedoch nur gesendet, wenn ein Wechsel in den freien oder gestörten Zustand erfolgt.

Prinzipiell kann die Detektion in SWIM in zwei Schritte aufgeteilt werden. Im freien Verkehr wird die Störungserkennung durchgeführt. Nach Erkennen einer Störung folgt die Detektion des Übergangs vom gestörten zum freien Verkehr. Diese Unterteilung wird nachfolgend bei der Beschreibung von SWIM verwendet. Die Parameter der Einfahrt und der Ausfahrt werden zusammengefasst am Ende von Kapitel 6 in Tabelle 6.8 aufgelistet.

5.5.1. Erkennung der Störungseinfahrt und der instabilen Bereiche

Im Folgenden wird das Vorgehen bei der Detektion von Instabilitäten und Störungen beschrieben. Abbildung 5.13 zeigt das Vorgehen grafisch. Das Verfahren liest sekundlich aktuelle XFCD-Daten ein. Im *freien Verkehr* überprüft SWIM die stochastischen Modelle M1 und M2 aus Abschnitt 5.4. Dabei muss eines der Modelle eine Störung erkennen. Zusätzlich wird die Tiefe

und Stärke eines Geschwindigkeitsabfalls betrachtet (siehe Abb. 5.14). Bei großen Geschwindigkeitsdifferenzen auf ein niedrigeres Geschwindigkeitsniveau wechselt SWIM in den Zustand des *instabilen Verkehrs*. Dabei müssen folgende Kriterien erfüllt sein:

$$\Delta v > v_{\Delta instabil} \quad (M3) \quad \text{und} \quad v_t < v_{schwelle_unruhe} \quad (5.5)$$

oder

$$\Delta v > v_{\Delta stau} \quad (M3) \quad \text{und} \quad v_t < v_{schwelle_stau} \quad (5.6)$$

Da die Detektion der stochastischen Modelle etwas verzögert zu der Erkennung der Geschwindigkeitsdifferenzen erfolgt, untersucht SWIM zu jedem Zeitpunkt die Modelle M1-M3 für die letzten 11 Sekunden ($t, t-1, \dots, t-10$). In diesem Zeitintervall muss entweder Modul M1 oder M2 sowie Modul M3 die bereits beschriebenen Kriterien erfüllen.

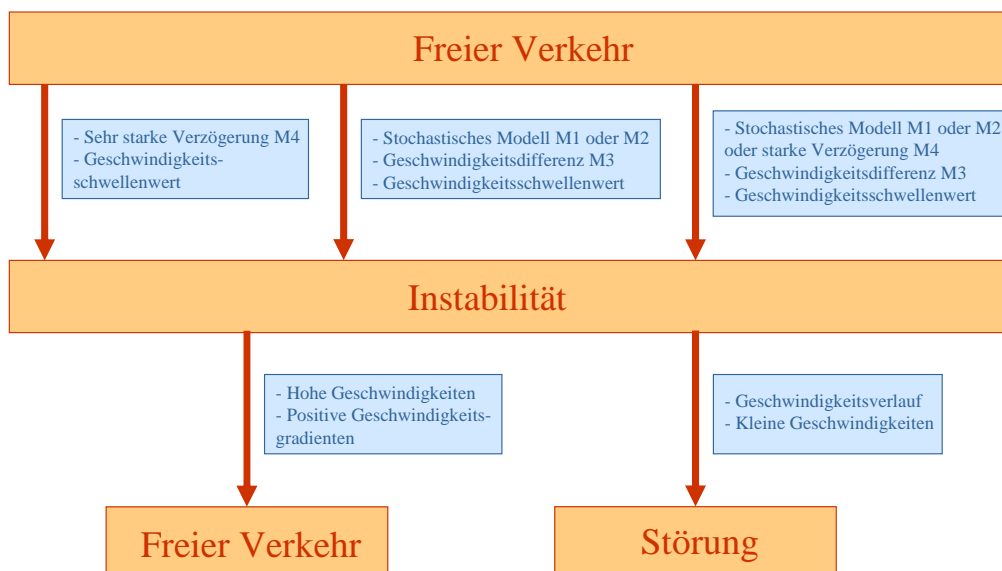


Abbildung 5.13.: Erkennung der Störungseinfahrt von SWIM

Falls der Fahrer gezwungen ist, bei der Einfahrt in eine Störung sehr stark abzubremsen, kann dies die stochastische Erkennung M1 und M2 ersetzen und stattdessen mit Gleichung 5.6 überprüft werden:

$$a > a_{steil1} \quad (M4)$$

Ebenso kann eine Instabilität erkannt werden, wenn eine sehr starke Bremsung mit $a > a_{steil2}$ auf eine Geschwindigkeit $v_t < v_{schwelle_im_stau}$ erfolgt.

Falls sich der Verkehr im Bereich des *instabilen Verkehrs* befindet, wird für jeden Zeitschritt geprüft, ob eine der folgenden Bedingungen

$$v_t < v_{schwelle_im_stau} \quad (5.7)$$

oder

$$\frac{1}{10} \cdot \sum_{j=0}^9 v_{t-j} < v_{schwelle_kurzstau} \quad (5.8)$$

gilt. Dann ist prinzipiell eine Störung erkannt. Dies gilt auch bei Erfüllung der Bedingungen M1 und M2 oder M4 in Zusammenhang mit Gleichung 5.6. Um die Robustheit zu erhöhen und fehlerhafte Meldungen zu vermeiden, wird eine Störungsmeldung jedoch erst versendet, wenn eine bestimmte Zeit $t_{warte} \geq T_{wartezeit}$ erreicht wird. Diese ergibt sich zu:

$$t_{warte} = \begin{cases} t_{warte} + 1, & \text{falls Gleichung 5.7} \\ t_{warte} + T_{verzoeigerung}, & \text{falls Gleichung 5.8} \end{cases}$$

Die Variable $T_{verzoeigerung}$ bewirkt, dass der Algorithmus bei geringen Geschwindigkeiten schneller in den Zustand Störung wechselt. Als Stauereinfahrt wird der Zeitpunkt definiert, an dem der Übergang in den instabilen Verkehrszustand erfolgte.




Abbildung 5.14.: Schwellenwerte bei der Einfahrt in die Störung

Wird keine Störung erkannt und übersteigt die Geschwindigkeit bei positivem Geschwindigkeitsgradienten einen Schwellenwert $v_{schwelle_frei}$ wird der Zustand frei angenommen.

5.5.2. Erkennung der Störungsausfahrt

Abbildung 5.15 zeigt das Vorgehen zur Erkennung der **Ausfahrt** aus einer Störung. Dabei wird überprüft, ob innerhalb der letzten 11 Zeitschritte eine Niveauänderung im stochastischen Modell M1 auftrat. Auch hier werden zwei Parametersätze für das Niveauänderungsmodell verwendet. Im Gegensatz zum Modell für die Störungseinfahrt muss die Differenz zwischen der Länge der betrachteten Zeitreihe n und dem Eintritt der Störung T groß gewählt werden (vgl. Parameterwerte Anhang). Während der Geschwindigkeitsabfall bei der Einfahrt in die Störung scharf ist, erstreckt sich die Ausfahrt aus einer Störung über eine längere Strecke. Der Algorithmus

mus kann eine Änderung erst dann erkennen, wenn ein neues Geschwindigkeitsniveau erreicht wurde. Darüber hinaus muss für die Geschwindigkeitsdifferenz

$$\Delta v > v_{\Delta aus} \quad \text{und} \quad v_t > 80 \frac{km}{h}$$

gelten. Eine Ausfahrt wird prinzipiell auch dann erkannt, wenn gilt:

$$\frac{1}{11} \cdot \sum_{j=0}^{10} v_{t-j} > 80 \frac{km}{h}$$

Wie bei der Einfahrt in eine Störung wird eine Meldung jedoch erst dann versendet, wenn $v_t > v_{schwelle_stau}$ für $T_{wartezeit_ausfahrt}$ Sekunden gilt.

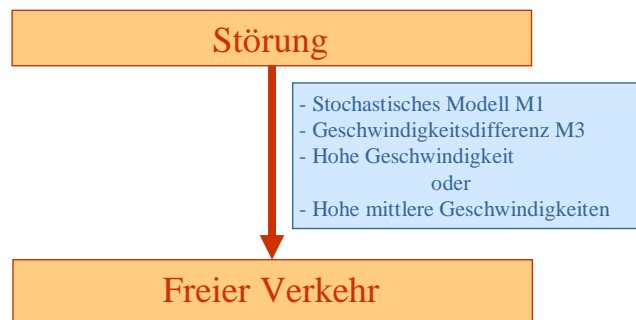


Abbildung 5.15.: Erkennung der Ausfahrt aus der Störung

5.5.3. Bestimmung der Parameter

Das neue Verfahren SWIM enthält 27 Parameter, welche die Qualität des Verfahrens im Einsatz beeinflussen können. Es ist nicht möglich, alle Parameter festzulegen. Sie müssen folglich geschätzt werden. Von den 27 Parametern können 16 aus übergeordneten Überlegungen, etwa im Laufe der Modellentwicklung, gewählt werden. Es bleiben 11 Parameter, die im Rahmen eines Optimierungsverfahrens bestimmt werden müssen. Diese Parameter sind in Tabelle 5.6 aufgezählt. Ihr Definitionsbereich wird aufgrund der Ergebnisse der Modellentwicklung und unabhängigen Zielkriterien bestimmt.

Wie bei den Neuronalen Netzen erschwert die hohe Dimension an Parametern unter anderem Aussagen über den Verlauf der Funktion im Parameterraum sowie ihrer Gradienten. Da eine analytische Berechnung der zu optimierenden Funktion nicht möglich ist, können Verfahren wie beispielsweise das Gradientenabstiegsverfahren, nicht verwendet werden. Unter den möglichen Verfahren, wie etwa Simulated Annealing, wird ein genetischer Algorithmus gewählt. Genetische Algorithmen zeichnen sich durch ihre Robustheit und Effizienz bei der Optimierung in großen Suchräumen aus. Zusätzlich haben sie den Vorteil eines geringen Program-

mieraufwands. Allerdings garantieren auch sie nicht das Erreichen des globalen Optimums.

Parameter	Parametergrenzen
$v_{schwelle_stau}$	[30; 70]
$v_{schwelle_im_stau}$	[30; 70]
$v_{schwelle_unruhe}$	[50; 90]
$T_{wartezeit}$	[1; 100]
$T_{verzoegerung}$	[1; 30]
$T_{wartezeit_ausfahrt}$	[0; 60]
$v_{schwelle_kurzstau}$	[10; 60]
$v_{\Delta instabil}$	[30; 60]
$T_{instabil}$	[10; 60]
$n_{Aus,2}$	[50; 200]
$T_{Aus,2}$	[50; 100]

Tabelle 5.6.: Zu optimierende Parameter von SWIM

Für die Optimierung der Parameter und der späteren Evaluation der Verfahren wird ein Gütemaß benötigt, das festlegt, wie gut ein Verfahren eine Störung erkennt. Dazu werden im nächsten Kapitel Gütekriterien vorgestellt. Weiter ist ein Referenzverfahren notwendig, mit dem auf der Basis repräsentativer Szenarien die Güte des Verfahrens berechnet werden kann. Diese werden ebenfalls im folgenden Kapitel beschrieben. Auf dieser Basis kann dann die Optimierung der Parameter anhand des genetischen Algorithmus durchgeführt werden.

6. Untersuchungsmethodik zur Optimierung und Bewertung von SWIM

Für die Optimierung von SWIM und zur vergleichenden Bewertung der Verfahren zur Erkennung von Verkehrsstörungen auf Basis von XFCD-Daten wird ein simulationsbasierter Ansatz gewählt. Als Werkzeug dient der (sub-)mikroskopische Verkehrssimulator PELOPS. Basierend auf der in Kapitel 3 vorgestellten Definition von Verkehrsstörung werden nachfolgend Gütekriterien präsentiert, mit denen die Qualität von mikroskopischen Erkennungsverfahren bestimmt werden kann. Schließlich wird ein Referenzverfahren als Bewertungsgrundlage vorgestellt und der Aufbau der Evaluationsszenarien beschrieben. Aufbauend auf diesen wird eine Parameteroptimierung des neuen Verfahrens SWIM durchgeführt.

6.1. Gesamtkonzept

Die Kenntnis über die Qualität eines Verfahrens ist für den Einsatz in der Praxis ein wichtiges Kriterium. Die Erkennung von Verkehrsstörungen auf der Basis mobiler Daten ist ein junges Gebiet, für das bisher keine allgemein anerkannte Definition von Verkehrsstörung existiert. Objektive Aussagen über die Qualität bisher entwickelter Verfahren sind daher so gut wie nicht vorhanden. Um Aussagen über die Qualität des beschriebenen Verfahrens treffen zu können, ist es notwendig, ein Bewertungsverfahren zu entwickeln, das speziell auf die Anforderungen einer mobilen Erkennung zugeschnitten ist und die Qualität hinsichtlich deren Zielsetzung quantifiziert. Bei der Störungserkennung ist das Ziel die robuste Erkennung einer vorhandenen Störung. Es ist zielführend, ein Referenzverfahren zu entwickeln, das bezüglich der gewählten Gütekriterien optimal ist.

Die Bewertung verläuft wie in Abbildung 6.1 beschrieben. Ein Verfahren wird „quasi“ online für eine bestimmte Anzahl an simulierten Fahrzeugen getestet. Für jeden Zeitschritt der Fahrt entscheidet der Algorithmus, ob das Fahrzeug in eine Störung einfährt, ausfährt oder ob es sich in einem Stau befindet. Die Erkennung wird dann mit der des Referenzverfahrens verglichen und anhand der nachfolgend eingeführten Gütekriterien bewertet.

Die Bewertung der Verfahren erfolgt auf der Basis simulierter Daten, da es bei Realdaten nicht praktikabel war, einen Referenzfall anzugeben. Dazu wäre eine repräsentative Datenbank an realen XFCD-Fahrten mit einer objektiven Referenz wie etwa detaillierten Aufzeichnungen oder örtlich fein aufgelösten stationären Beobachtungen notwendig. Dennoch sind aufge-

gezeichnete Realdaten vorhanden. Diese werden zusätzlich zur Plausibilisierung herangezogen.

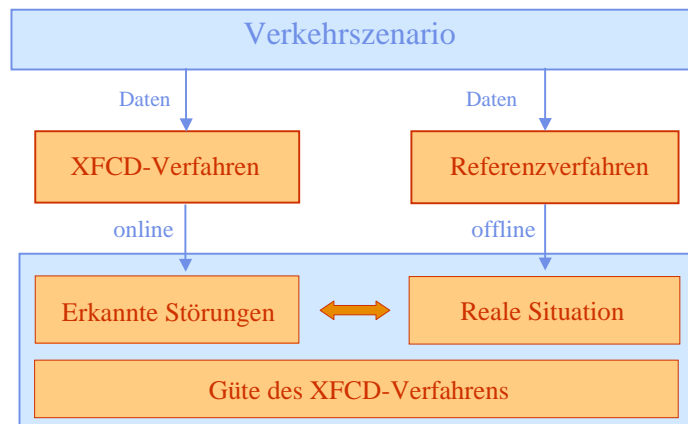


Abbildung 6.1.: Berechnung der Güte von XFCD-Verfahren

Abbildung 6.2 zeigt die Umgebung für die Entwicklung, die Optimierung und die Bewertung von XFCD-Verfahren. Die Verfahren sind in MATLAB/SIMULINK implementiert. Die Störungserkennung kann mit Daten aus realen Testfahrten ebenso durchgeführt werden wie mit simulierten Daten. Dabei liegt wie zuvor beschrieben der Schwerpunkt auf der Verwendung von simulierten Daten.

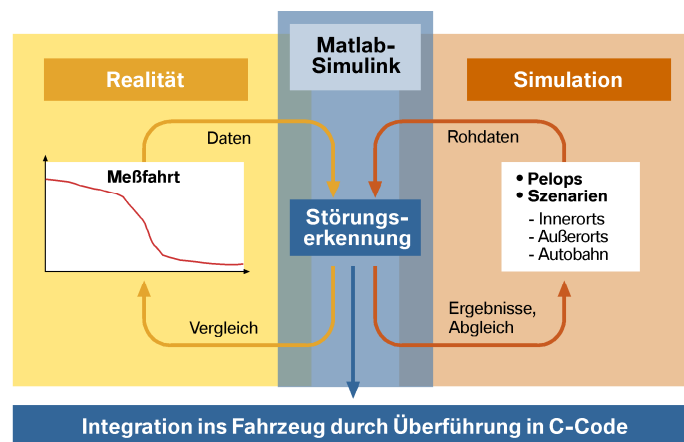


Abbildung 6.2.: Emulationsumgebung für die Entwicklung, die Optimierung und die Bewertung von XFCD-Verfahren

Prinzipiell besteht der Versuchsaufbau aus zwei Ebenen (siehe Abb. 6.3). Die Ebene der Verkehrssimulation modelliert den eigentlichen Verkehrsablauf. Darauf aufgesetzt laufen Prozesse ab, die vom aktuellen Verkehrszustand abhängig sind. Dies können alle Arten von Daten verarbeitenden Prozessen wie fahrzeugautonome Zustandserkennung, Zielführung, Kommunikationsprozesse zwischen Fahrzeugen und Infrastruktur aber auch makroskopische Verkehrssteuerungen sein. In Wirklichkeit können sich diese Prozesse auf den Verkehrsfluss auswirken. So

können beispielsweise den Fahrzeugen andere Routen zugewiesen werden. In dieser Arbeit wird die Verarbeitung der Fahrzeugdaten zu einer Aussage über das Vorliegen einer Verkehrsstörung emuliert, jedoch findet keine Rückkopplung statt. Die beiden Ebenen können somit getrennt voneinander betrachtet werden.

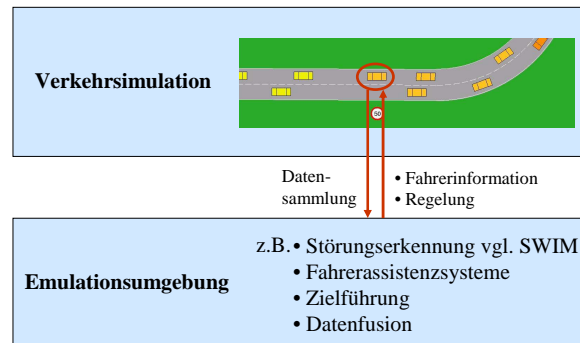


Abbildung 6.3.: Darstellung des Versuchsaufbaus in zwei Ebenen

Im Folgenden wird der in dieser Arbeit verwendete Verkehrssimulator beschrieben. Die Emulationsumgebung wird in Abschnitt 6.6 dargestellt.

6.2. Simulationsumgebung PELOPS

Verkehrssimulationen eignen sich in hohem Maße für die Entwicklung von prototypischen Verfahren und Systemen. Oft ist es nicht möglich, zukünftige Systeme in der Realität zu testen. Feldversuche sind mit hohen zeitlichen und finanziellen Aufwendungen verbunden und daher nur in der Endphase einer Entwicklung sinnvoll. Um im Vorfeld schon Aussagen über Qualität und verkehrliche Wirksamkeit treffen zu können sind Simulationen ein weit verbreitetes Instrument. In dieser Arbeit wird der (sub-)mikroskopische Verkehrssimulator PELOPS¹ für die Entwicklung und die Bewertung der Erkennungsverfahren auf Streckenabschnitten genutzt. Dabei erfolgt die Untersuchung der Verfahren für Autobahnen. Für zukünftige Untersuchungen muss jedoch eine Simulation im Netz zur Verfügung stehen. Dann ist eine Simulation mit PELOPS allein nicht mehr möglich. Eine Möglichkeit könnte die Verwendung einer gekoppelten Version von PELOPS mit VISSIM² darstellen.

¹Programmsystem zur Entwicklung Längsdynamischer mikroskopischer Verkehrsprozesse in Systemrelevanter Umgebung

²Verkehr in Städten - Simulation

6.2.1. Verkehrssimulator PELOPS

Der Verkehrssimulator PELOPS wurde vom Institut für Kraftfahrtwesen in Aachen (ika) in Zusammenarbeit mit der BMW AG im Rahmen des Projekts PROMETHEUS³ konzipiert und entwickelt. Bei der Entwicklung von Fahrzeug-Regelsystemen wie etwa von erweiterten Geschwindigkeits- und Abstandsreglern (ACC) wuchs der Bedarf, die entstandenen Prototypen zu testen und Aussagen über verkehrliche Wirkungen auch in Abhängigkeit der Ausstattungsraten zu treffen. Existierende mikroskopische Modelle konnten die Voraussetzungen in dem Detaillierungsgrad nicht erfüllen. Aus diesem Grund entstand der Simulator PELOPS als eine Mischung von submikroskopischen Fahrzeugmodellen und mikroskopischen Verkehrsmodellen. Seine Entwicklung wurde verstärkt im Projekt MOTIV⁴ vorangetrieben. Heute wird PELOPS von der Forschungsgesellschaft für Kraftfahrtwesen (fka) in Aachen gepflegt und vertrieben.

Ein Schwerpunkt des Einsatzes von PELOPS liegt in der Entwicklung und Optimierung von fahrzeugautonomen Fahrerassistenzsystemen. Neben den Parametern, die für die Auslegung der Systeme verantwortlich sind, können Kraftstoffverbrauch und Emissionen analysiert werden. Die Bewertung erfolgt jedoch nicht nur aus dem Blickwinkel des einzelnen Fahrzeugs. Es werden insbesondere auch die verkehrlichen Auswirkungen wie Zeitlücken, Durchsatz oder die Stabilität von Fahrzeugkolonnen untersucht. Ein weiteres Anwendungsgebiet von PELOPS ist die Untersuchung von infrastrukturgestützten Maßnahmen zur Verkehrsbeeinflussung. Ein Beispiel hierfür ist das straßenseitige Warnsystem COMPANION [KATES ET AL. 1999]. Seit ein paar Jahren werden in der Abteilung Verkehrstechnik (EW-1) der BMW AG verstärkt Analysen des Verkehrsablaufs und weiterführende verkehrstechnische Untersuchungen durchgeführt.

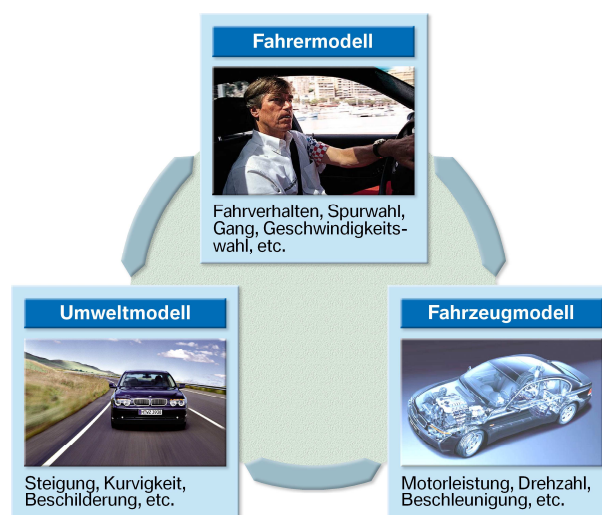


Abbildung 6.4.: Wechselwirkungen zwischen den Hauptelementen des Verkehrs

³Programme for a European Traffic with Highest Efficiency and Unprecedented Safety

⁴Mobilität und Transport im intermodalen Verkehr

PELOPS arbeitet zeitschrittbasiert. Aufgrund seiner modulartigen Programmstruktur ist es möglich, Modelle unterschiedlichen Detaillierungsgrades einzubinden. Ein besonderes Augenmerk wurde auf die Wechselwirkungen zwischen den Hauptkomponenten Fahrer, Fahrzeug und Umwelt gelegt (siehe Abb. 6.4). Für eine umfassende Analyse ist es nicht ausreichend, ein Fahrzeug losgelöst von den Einflüssen seiner Umgebung zu analysieren. Sein Fahrtverlauf wird von den Fahrzeugeigenschaften, seinem Fahrer sowie dem gegenwärtigen Verkehrskontext beeinflusst. Umgekehrt beeinflusst es mit seinem Fahrverhalten das Gesamtsystem Verkehr. Auf diese Weise können sowohl fahrzeugtechnische als auch verkehrstechnische Fragestellungen untersucht werden. Dazu stehen in PELOPS verschiedene Bewertungswerkzeuge zur Verfügung. Neben mikroskopischen Ausgabegrößen wie punktuelle Geschwindigkeiten, Beschleunigungen etc. können auch makroskopische Größen wie durchschnittliche Geschwindigkeiten, Verkehrsstärken, Verkehrsdichten und Reisezeiten bestimmt werden.

Nachfolgend werden die einzelnen Module des Verkehrssimulators PELOPS kurz beschrieben.

Streckenmodell

Mit dem Streckenmodell können unterschiedliche Streckentopologien modelliert und die Einflüsse von Kurven und Steigungen auf den Verkehr dargestellt werden. Zudem ist die Steuerung des Verkehrs über Verkehrsbeeinflussungsanlagen wie Beschilderungen und Lichtsignalanlagen möglich.

Fahrermodell

Das Fahrermodell gliedert sich in ein Verhaltensmodell und ein Handlungsmodell (siehe Abb. 6.5). Im Verhaltensmodell entsteht in Abhängigkeit von der gegenwärtigen Fahrsituation und der Verkehrsumgebung eine Fahrabsicht, die sich in einer Wunschbeschleunigung und einer Spurwahl äußert. Die Entscheidung wird basierend auf einem Folgemodell und einem Spurwechselmodell getroffen [HOCHSTÄDTER ET AL. 2000]. Im Handlungsmodell werden die Parameter der oben bestimmten Fahrstrategie in fahrzeugseitige Stellgrößen der Bedienelemente Gaspedalstellung und Gang umgesetzt.

Als Folgemodell wurde ein psycho-physisches Distanzmodell implementiert, das auf einer Erweiterung der Arbeiten Wiedemanns basiert [WIEDEMANN 1974]. Der Fahrer wird anhand einer Reihe von Parametern charakterisiert. Die Berechnung der Wunschbeschleunigung erfolgt in Abhängigkeit der Fahrsituation, in der sich der Fahrer befindet. Das Modell nach WIEDEMANN ist nur für das längsdynamische Verhalten auf einspurigen Strecken geeignet. Um Verkehr auf mehrspurigen Strecken sowie Situationen, bei denen der Fahrer auf Gegebenheiten

der Streckentopologie reagieren muss, zu simulieren, wurde das Verhaltensmodell um ein Spurwechselmodell erweitert. Dieses berücksichtigt neben „Standardsituationen“ auch taktisches Fahrverhalten wie etwa Spurwegfall [HOCHSTÄDTER ET AL. 2000].

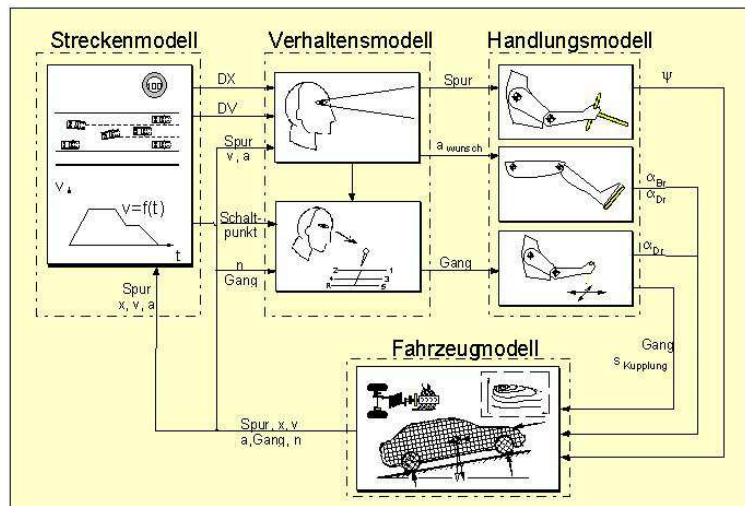


Abbildung 6.5.: Modularer Aufbau von PELOPS (Quelle: [HOCHSTÄDTER ET AL. 2000])

Fahrzeugmodell

PELOPS enthält zwei Fahrzeugmodelle. Bei den detailliert abgebildeten Realfahrzeugen werden die fahrzeugseitigen Kenngrößen gemäß dem realen Ursache-Wirkungs-Prinzip in dynamische Stellgrößen umgewandelt. Die genaue Abbildung der Elemente des Antriebsstranges wie Motor, Getriebe, Retarder etc. ermöglichen die Untersuchung regelungstechnischer Fahrerassistenzsysteme wie zum Beispiel ACC.

Manchmal ist es allerdings nicht notwendig, Fahrzeuge mit hoher Genauigkeit abzubilden. Dies ist der Fall, wenn wie bei Fahrerassistenzsystemen nur ein Teil der Fahrzeuge ausgestattet wird. Dann ist es möglich, ein vereinfachtes Modell einzubinden, für das eine unterschiedliche Anzahl an Fahrzeugen standardmäßig in PELOPS abgebildet sind und das die kinematischen Zusammenhänge beschreibt. Diese Fahrzeuge können keine Fahrerassistenzsysteme enthalten. Sie dienen also zur schnellen Erzeugung von hohen Verkehrsstärken, um bestimmte verkehrstechnische Fragestellungen zu untersuchen.

6.2.2. Erweiterungen von PELOPS

Externe Komponenten wie Fahrzeugmodelle oder Regelalgorithmen können in PELOPS über eine universelle Schnittstelle, dem sog. XFACE⁵, eingebunden werden. XFACE wurde bei der

⁵Exchange Interface

BMW AG mit dem Ziel entwickelt, externe Komponenten an unterschiedliche Anwendungen wie dem Verkehrssimulator PELOPS oder der BMW-Fahrsimulatorsoftware SPIDER⁶ über eine gemeinsame Schnittstelle anzuhängen. Die Anbindung erfolgt entweder direkt über Sourcecode oder über einen online-Datenaustausch zu MATLAB/SIMULINK. In XFACE werden Datenstrukturen zur Verfügung gestellt, die Informationen über die Fahrumgebung des Fahrzeugs enthalten. Diese betreffen die Beschreibung der Strecke und die Sicht auf umgebende Fahrzeuge. Weiter gibt es Containerklassen für die Einbindung der oben genannten Modulfunktionalitäten [CHRISTEN 2004].

Im Rahmen des Projekts INVENT VLA wurde die Schnittstelle XFACE dahingehend erweitert, dass simulierte Realfahrzeuge über Fahrzeug-Fahrzeug-Kommunikation Informationen austauschen können [VLA 2004]. In diesem Zusammenhang wurde ein Reglertyp XFCD geschaffen, der als Sourcecode direkt in PELOPS eingebunden wird. Ein mit diesem Regler ausgestattetes XFCD-Fahrzeug zeichnet während der Simulation genau die Daten auf, die von den Erkennungsverfahren als Dateneingabe benötigt werden. Diese Daten stehen zum Großteil nicht in der von PELOPS erzeugten Ausgabedatei zur Verfügung. Durch eine Modellierung der XFCD-Fahrzeuge als geregelte Fahrzeuge ist es jedoch möglich, über XFACE auf die in PELOPS abgebildeten Daten der Fahrumgebung, sowie der „internen“ Größen wie beispielsweise des Radeinschlagwinkels zuzugreifen. Diese Art von Größen ist bei anderen mikroskopischen Modellen nicht abgreifbar.

Der Datenaustausch zwischen Simulationsumgebung und XFCD-Fahrzeug ist einseitig implementiert. Das bedeutet, dass die XFCD-Fahrzeuge nur Daten aus der Simulation extrahieren. Eine Rückkopplung ist an dieser Stelle nicht realisiert. Jedes XFCD-Fahrzeug schreibt seine Daten in eine eigene Textdatei. Zusätzlich ist es auch möglich, XFCD-Fahrzeuge über eine MATLAB/SIMULINK-Kopplung anzubinden. Auf diese Weise kann jedoch nur ein einzelnes Fahrzeug ausgestattet werden.

6.3. Aufbau der Szenariendatenbank

Als Versuchsstrecke wird exemplarisch ein Streckenabschnitt der A9 gewählt und für diesen eine Szenariendatenbank aufgebaut. Die Strecke befindet sich im Norden Münchens und stellt einen der Stauschwerpunkte Münchens dar. Der durchschnittliche tägliche Verkehr im Jahresmittel (DTV) beträgt auf diesem Abschnitt etwa 125.500 $\frac{\text{Kfz}}{24\text{h}}$ [AUTOBAHNDIREKTION SÜDBAYERN 2002].

⁶Software Programming Interface for Distributed Realtime Driving Simulation

6.3.1. Streckenbeschreibung

Das Untersuchungsgebiet befindet sich zwischen der Autobahnanschlussstelle Eching und dem Autobahnkreuz München-Nord (siehe Abb. 6.6). Die dreispurige Strecke wird in Fahrtrichtung München zwischen Kilometer 514.17 und Kilometer 521.67 betrachtet. Auf die Modellierung von Auf- und Abfahrten wird verzichtet, da in dieser Arbeit nur die Erkennung der Wirkung eines externen Ereignisses untersucht wird und nicht die Dynamik der Störung.



Abbildung 6.6.: Streckenverlauf A9

Messquerschnitt	Kilometer
MQ 19	514.17
MQ 20	514.83
MQ 21	516.10
MQ 22	517.49
MQ 23	518.66
MQ 24	519.33
MQ 25	520.83
MQ 26	521.17

Tabelle 6.1.: Messquerschnitte innerhalb des Untersuchungsgebiets

Der betrachtete Streckenabschnitt enthält sieben Messquerschnitte, wobei Messquerschnitt 19 den ursprünglichen Streckenanfang darstellt (siehe Tabelle 6.1). Die Strecke wird am Anfang künstlich um einen Kilometer verlängert, um ein unfallfreies Befahren der Strecke zu gewährleisten. Das hat zusätzlich den Vorteil, dass sich Störungen, deren Ursprünge sich nahe am Streckenanfang befinden, sich weiter stromaufwärts ausbreiten können, ohne sofort die Einfahrt der nachkommenden Fahrzeuge auf die Strecke zu versperren. Die Streckenlänge beläuft sich auf 8500m.

6.3.2. Szenariendatenbank basierend auf realen Unfalldaten

Um repräsentative Aussagen über die Qualität eines Erkennungsverfahrens treffen zu können, ist es wichtig, die Verfahren an einer großen Bandbreite an Verkehrsstörungen zu untersuchen. Zu diesem Zweck wird gemäß HOOPS ET AL. (1999) eine entsprechende Szenariendatenbank basierend auf realen Messquerschnitts- und Unfalldaten aufgebaut. Die Daten stammen ebenfalls aus dieser Untersuchung.

Kalibrierung und Simulationsdurchführung mit PELOPS

Für die Erzeugung des Evaluationsszenarios stehen reale Geschwindigkeits- und Verkehrsstärkedaten an einem repräsentativen Messquerschnitt für einen typischen Tag in dem gewählten Versuchszeitraum zur Verfügung. Damit nachfolgend beschriebene Eingriffe in den Verkehrsablauf zu Verkehrsstörungen anwachsen, wird für die Simulation der Zeitabschnitt mit der höchsten Verkehrsstärke gewählt. Dieser befindet sich gegen 8:00. Die Kalibrierung wird dann für den Zeitraum zwischen 8:00 – 12:00 durchgeführt. Dazu wird das Versuchsszenario simuliert und die Geschwindigkeits- und Verkehrsstärkedaten an den virtuellen Messschleifen gemessen. Die Messdaten werden anschließend mit den Daten des Versuchstages überprüft. Für die kalibrierte Strecke wird eine Fahrerpopulation mit 1500 Fahrzeugen erzeugt. Davon sind 20% der Fahrzeuge XFCD-Fahrzeuge.

Da sich zu Beginn einer Simulation normalerweise keine Fahrzeuge auf der Strecke befinden, wird die Strecke vor der eigentlichen Simulation eine halbe Stunde mit Realdaten vorsimuliert. Dazu wird das Intervall zwischen 7:30 und 8:00 verwendet. Die so erzeugte neue Vorgabedatei beinhaltet Fahrzeuge, die sich bereits auf der Strecke befinden und schafft so realitätsnahe Anfangsbedingungen für die Simulation.

Die Simulationsdauer beträgt 45 Minuten. Die Fahrzeuge werden am Streckenanfang makroskopisch gemäß der Realdaten für das Zeitintervall 8:00 – 9:00 eingesetzt. Der Lkw-Anteil beträgt dabei circa 13%. Das sich so ergebende Basisszenario ist in Abbildung 6.7 abgebildet.




Abbildung 6.7.: Basisszenario: Szenario ohne erzeugte Störung

Erzeugung von Verkehrsstörungen

Die realen Unfalldaten gewährleisten eine realistische Verteilung der empirischen Störungspositionen. Dies ist insofern von Bedeutung, als dass bestimmte Streckenabschnitte Unfall-

schwerpunkte oder Gefahrenpotentiale darstellen. Beispiele dafür sind unübersichtliches Gelände mit Kurven oder Steigungen, die den Fahrer und damit den Verkehr stark beeinflussen.

Die Unfalldaten stammen aus dem Zeitraum vom 1.11.97 – 28.2.98. Es werden diejenigen Unfälle ausgewählt, die innerhalb der Versuchsstrecke liegen. Von diesen 35 Unfällen werden alle, die vor Kilometer 516 auftraten, ausgeschlossen, um zu verhindern, dass sich die Störungen zu schnell bis an den Streckenanfang fortpflanzen. Aus den restlichen 26 Unfallpositionen werden schließlich diejenigen, die in unmittelbarer Nähe liegen zusammengefasst. Insgesamt bleiben 13 Unfallorte zur Bewertung (siehe Tabelle 6.2).

Szenario	1	2	3	4	5	6	7
Position	516.0	516.7	517.0	517.22	517.55	518.5	518.75
Szenario	8	9	10	11	12	13	
Position	518.95	519.51	520.22	520.5	520.95	521.1	

Tabelle 6.2.: Positionen der Störungen im Szenario

Die Erzeugung der Störungen in der Simulation wird vorwiegend über Spursperrungen realisiert. Da nicht bekannt ist, um welche Art von Unfällen es sich handelt, müssen alle möglichen Sperrungen untersucht werden (siehe Tabelle 6.3). Zu diesem Zweck werden Zyklusfahrzeuge eingesetzt, deren Streckenverlauf vorgegeben werden kann. Diese Fahrzeuge halten an der angegebenen Unfallstelle an und fahren nach einer kurzen Haltezeit weiter. Die Haltezeit wird bei Einfachsperrungen auf 15 Minuten gesetzt, bei Sperrungen von mehreren Spuren auf 5 Minuten. Diese Begrenzung hat auch hier wieder den Zweck, die Fortpflanzung der Störungen an den Streckenanfang zu verhindern. Außerdem wird für 15 Minuten eine Kapazitätsreduktion simuliert. Diese führt dazu, dass die passierenden Fahrzeuge innerhalb eines 1km langen Streckenabschnitts ein höheres Sicherheitsbedürfnis haben, welches wiederum den Folgeabstand stark beeinflusst. Die Folge sind größere Abstände zwischen den Fahrzeugen und damit ein Kapazitätsverlust der Strecke. Im freien Verkehr wirkt sich dieser Kapazitätsverlust nicht aus. Die Fahrzeuge fahren mit unveränderter Geschwindigkeit. Ab einer bestimmten Verkehrsstärke bewirken die größeren Abstände die Entstehung eines Staus.

Für die Optimierung der Parameter von SWIM werden drei Testszenarien mit veränderten Randbedingungen aufgesetzt. Zwei der Szenarien enthalten eine einzelne Spursperrung während für das dritte Szenario eine Kapazitätsreduktion simuliert wird. Die Position der Störungen wird zufällig festgelegt.

Szenario	linke Spur	mittlere Spur	rechte Spur
Ursache 1	-	-	x
Ursache 2	-	x	-
Ursache 3	x	-	-
Ursache 4	Kapazitätsreduktion		
Ursache 5	x	x	x
Ursache 6	-	x	x
Ursache 7	x	x	-
Ursache 8	x	-	x

Tabelle 6.3.: Modellierte Störungsursachen

6.3.3. Modellierung von Sonderszenarien

Zur Untersuchung des Verhaltens der Algorithmen bei aufeinander folgenden Störungen bzw. bei Stop-&-Go Verkehr werden vier zusätzliche Evaluationsszenarien aufgebaut.

Der Szenarienaufbau erfolgt analog zu der Szenariendatenbank mit realen Unfalldaten. Auch hier wird eine Vorsimulation durchgeführt, um eine realistische Verteilung von Fahrzeugen auf der Strecke zu erhalten. Dagegen beträgt die Simulationszeit 30 Minuten; 40% der 800 Fahrzeuge sind zu XFCD-Fahrzeugen ausgestattet. Die Störungen werden mit Hilfe zweier Zyklusfahrzeuge entsprechend der Daten aus Tabelle 6.4 verursacht. Während zur Erzeugung der ersten Störung jeweils mindestens zwei Spuren gesperrt werden, hält an der zweiten Position nur ein Zyklusfahrzeug.

Szenario	Position 1	Haltezeit 1	Position 2	Haltezeit 2	Ursache 1. Störung
Szenario 14	km 5.73	Min. 3 – 8	km 8.0	Min. 10 – 15	Mittlere u. rechte Spur
Szenario 15	km 1.8	Min. 0 – 5	km 3.9	Min. 7 – 12	Vollsperrung
Szenario 16	km 4.53	Min. 2 – 8	km 6.23	Min. 9.5 – 15.5	Vollsperrung
Szenario 17	km 3.96	Min. 1 – 7	km 5.83	Min. 8.5 – 14.5	Mittlere u. rechte Spur

Tabelle 6.4.: Szenarien zur Erzeugung von aufeinander folgenden Störungen

6.4. Gütekriterien

Für die Bewertung von Erkennungsverfahren ist es zuerst notwendig, zu definieren, was eine gute Erkennung ausmacht und wie die Güte einer Erkennung für eine spezielle Applikation quantifiziert werden kann. Derartige Kriterien beeinflussen in direktem Maße die Nutzung von Meldungen von Verkehrsstörungen und können eine Aussage über den möglichen Schaden von fehlerhaften Meldungen treffen.

Abbildung 6.8 veranschaulicht die Ausgangssituation. Sie stellt mehrere Fahrzeugtrajektorien dar, die durch ein Staugebiet verlaufen. Für ein Fahrzeug sind exemplarisch die für die Be-

wertung relevanten Ereignisse dargestellt. Der rote Punkt markiert das Durchfahren der Störungsflanke. In Grün bzw. Blau sind das Erkennen bzw. Melden der Stauflanke gekennzeichnet. Das Fahrzeug kann die Meldung innerhalb einer Kommunikationsreichweite R an nachfolgende Fahrzeuge senden.

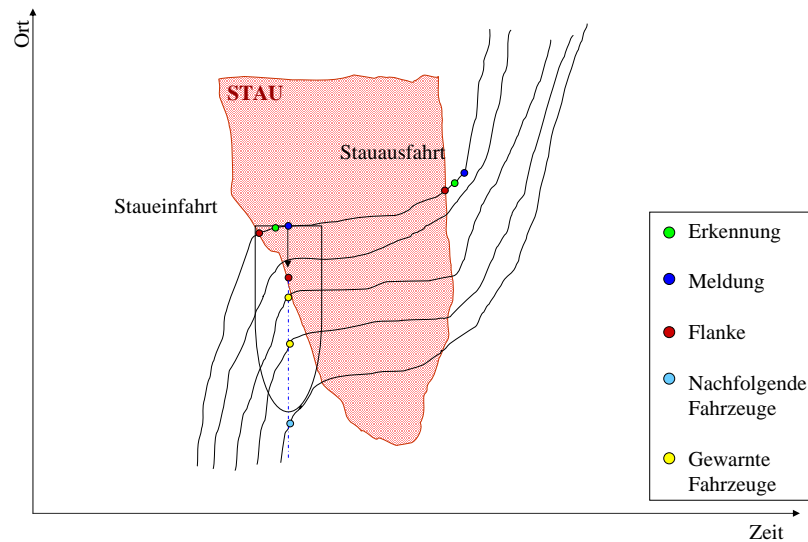


Abbildung 6.8.: Ausgangssituation: Darstellung eines Staus mit durchfahrenden Fahrzeugtrajektorien

6.4.1. Detektionsrate

Ein wichtiges Kriterium bei der Beurteilung von Erkennungsverfahren ist die Qualität der Erkennung von vorhandenen Störungen. Üblicherweise wird dazu das Verhältnis der Anzahl detektierter Störungen zu der Gesamtanzahl aufgetretener Störungen während der Beobachtungszeit angegeben [HOOPS ET AL. 1999]. Diese wird als **Detektionsrate** bezeichnet. Bei stationären Verfahren ist die Detektionsrate oft auch davon abhängig, welche Art von Störungen erkannt werden soll [BUSCH 1986]. Beschränkt sich die Erkennung auf Verkehrsstörungen, deren Wirkung sehr groß ist, erreicht man mit Sicherheit eine höhere Detektionsrate als mit Störungen geringer Auswirkung.

In dieser Arbeit soll eine detailliertere Definition der Detektionsrate verwendet werden. Die XFCD-Verfahren werden auf Autobahnabschnitten getestet. Dabei liegt die Hauptschwierigkeit nicht in der Erkennung der Störung, sondern in ihrer zeit- und ortsnahen Lokalisierung.

Es werden nachfolgend zwei Gütekriterien für die Detektion von Verkehrsstörungen vorgeschlagen.

Erkennung innerhalb einer bestimmten Reichweite

Das erste Kriterium macht eine Aussage über die Qualität der Erkennung in Abhängigkeit von der örtlichen und zeitlichen Lokalisierung. Für den praktischen Einsatz und für den Vergleich zu anderen Verfahren ist es wichtig, eine Aussage über die zeitliche Verzögerung, insbesondere aber den örtlichen Versatz zu machen. Dabei wird die Qualität der Erkennung für die Einfahrt und die Ausfahrt getrennt betrachtet.

Definition 6.1 [Detektionsrate] Die **Detektionsrate** gibt die Wahrscheinlichkeit an, dass eine vorhandene Stauflanke innerhalb eines Zeitintervalls λ und innerhalb eines örtlichen Versatzes δ erkannt wird. Dabei wird zwischen der Erkennung der Einfahrt DR_{Ein} und der Erkennung der Ausfahrt DR_{Aus} unterschieden.

$$DR_{Ein} = \frac{n_{E, Ein}}{n_{F, Ein}} \quad \text{und} \quad DR_{Aus} = \frac{n_{E, Aus}}{n_{F, Aus}}$$

wobei

- $n_{E, Ein}$: Anzahl durchfahrener Stauanfahrungen, die innerhalb der Schwellenwerte δ und λ erkannt wurden
- $n_{E, Aus}$: Anzahl durchfahrener Stauausfahrten, die innerhalb der Schwellenwerte δ und λ erkannt wurden
- $n_{F, Ein}$: Anzahl durchfahrener Stauanfahrungen bezüglich Referenzverfahren
- $n_{F, Aus}$: Anzahl durchfahrener Stauausfahrten bezüglich Referenzverfahren

Dabei muss gelten:

$$\Delta x = x_{E, Ein} - x_{F, Ein} < \delta \quad \text{bzw.} \quad \Delta x = x_{E, Aus} - x_{F, Aus} < \delta, \quad \delta \in \mathfrak{R}$$

und

$$\Delta t = t_{M, Ein} - t_{Ein} < \lambda \quad \text{bzw.} \quad \Delta t = t_{M, Aus} - t_{Aus} < \lambda, \quad \lambda \in \mathfrak{R}$$

mit

- (t_{Ein}, x_{Ein}) : Zeitpunkt und Position des Fahrzeugs bei Einfahrt in die Störung
- (t_{Aus}, x_{Aus}) : Zeitpunkt und Position des Fahrzeugs bei Ausfahrt aus der Störung
- $(t_{E, Ein}, x_{E, Ein})$: Zeitpunkt und Position des Fahrzeugs bei Erkennung der Einfahrt
- $(t_{E, Aus}, x_{E, Aus})$: Zeitpunkt und Position des Fahrzeugs bei Erkennung der Ausfahrt
- $(t_{M, Ein}, x_{M, Ein})$: Zeitpunkt und Position des Fahrzeugs bei Meldung der Einfahrt
- $(t_{M, Aus}, x_{M, Aus})$: Zeitpunkt und Position des Fahrzeugs bei Meldung der Ausfahrt
- $(t_{M, Ein}, x_{F, Ein})$: Zeitpunkt und Position der Stoßwelle zum Zeitpunkt der Meldung der Störungseinfahrt
- $(t_{M, Aus}, x_{F, Aus})$: Zeitpunkt und Position der Stauflanke zum Zeitpunkt der Meldung der Störungsausfahrt




Abbildung 6.9.: Bestimmung der Detektionsrate in Abhängigkeit der zeitlichen Verzögerung λ und des örtlichen Versatzes δ

Abbildung 6.9 veranschaulicht Definition 6.1 am Beispiel einer Staueinfahrt. Die blaue Trajektorie markiert wieder die Fahrt eines Fahrzeugs im Orts-Zeit-Diagramm. In Rot ist der Verlauf der Stoßwelle gezeichnet. Nachdem das Fahrzeug die Stauflanke passiert hat, vergeht die Zeit Δt bis das Fahrzeug zum Zeitpunkt $t_{M, Ein}$ eine erkannte Störungsposition $(t_{E, Ein}, x_{E, Ein})$ meldet. Zu diesem Zeitpunkt hat sich die Stauflanke möglicherweise in stromaufwärtige Richtung fortbewegt und befindet sich an Position $x_{F, Ein}$.

Eine Störung gilt nur dann als erkannt, wenn die gemeldete Stauflanke sich nicht weiter als $\Delta x < \delta$ von der aktuellen Stauflanke entfernt befindet. Außerdem darf eine zeitliche Differenz $\Delta t < \lambda$ zwischen Meldung und Staueinfahrt nicht überschritten werden. Gemäß obiger Definition wird eine Ausfahrt auch dann zur Bezugsmenge $n_{F, Aus}$ gezählt, wenn die Einfahrt nicht erkannt wurde. In dieser Arbeit wird somit ein Gütemaß verwendet, das die Summe der zu spät, der zu früh oder gar nicht erkannten Ein- bzw. Ausfahrten erfasst.

Mögliche Anzahl zusätzlich gewarnter Fahrzeuge

Das zweite Kriterium bezieht sich auf die Qualität der Erkennung im Hinblick auf die Warnung nachfolgender Fahrzeuge. Dabei liegt die Annahme zugrunde, dass die Fahrzeuge mit einer Kommunikationsreichweite R Informationen stromaufwärts versenden können. Weiter kann man davon ausgehen, dass ein Fahrzeug auf einer Autobahn nach einem Zeitintervall λ durch eine Streckenbeeinflussungsanlage gewarnt wird oder die Information veraltet. Letzteres ist dann der Fall, wenn die Stauffront außerhalb der Reichweite ist. Auch hier wird zwischen Ein- und Ausfahrt unterschieden.

Definition 6.2 [Warnrate] Ein Fahrzeug sende seine erkannten Stauplanken innerhalb einer Reichweite R stromaufwärts. Die **Warnraten** τ_{Ein} und τ_{Aus} sind der Anteil der Fahrzeuge, die zusätzlich vor einer Störungsein- bzw. Störungsausfahrt hätten gewarnt bzw. informiert werden können.

$$\tau_{Ein} = \frac{n_{Fzg, Ein} - n_{Fzg, M, Ein}}{n_{Fzg, Ein}} \quad \text{bzw.} \quad \tau_{Aus} = \frac{n_{Fzg, Aus} - n_{Fzg, M, Aus}}{n_{Fzg, Aus}}$$

mit

- $n_{Fzg, Ein}$: Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R bei Einfahrt in die Störung
- $n_{Fzg, Aus}$: Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R bei Ausfahrt aus der Störung
- $n_{Fzg, M, Ein}$: Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R und außerhalb der Störung bei Meldung der Einfahrt
- $n_{Fzg, M, Aus}$: Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R und außerhalb der Störung bei Meldung der Ausfahrt

Zusätzlich wird gefordert:

$$\Delta t = t_{M, Ein} - t_{Ein} < \lambda, \quad \lambda \in \mathfrak{R}$$




Abbildung 6.10.: Darstellung des Gewinns an zusätzlich gewarnten Fahrzeugen bei sofortiger Erkennung der Störung

Abbildung 6.10 veranschaulicht Definition 6.2 wieder am Beispiel der Einfahrt. Je später eine Störung erkannt und gemeldet wird, desto weniger Fahrzeuge können vor einer potentiellen Gefahrenstelle gewarnt werden ($\tau \mapsto 1$). Umgekehrt gilt bei sofortiger Erkennung und Meldung, dass alle nachkommenden Fahrzeuge gewarnt werden können ($\tau \mapsto 0$). Theoretisch kann der Fall $n_{Fzg, M, Ein} > n_{Fzg, Ein}$ auftreten. In diesem seltenen Fall wird $\tau = 0$ gesetzt.

Bei der Störungserkennung auf der Basis stationärer Daten wird in der Regel eine **Detektionszeit** berechnet, die die mittlere Zeit zwischen Auftreten der Störung und Detektion angibt.

Dies ist bei der Untersuchung eines einzelnen Fahrzeugs nicht sinnvoll. Ein Fahrzeug kann eine Störung erst dann detektieren, wenn es die Wirkung der Störung erfährt. Interessant wird die Detektionszeit jedoch in Zusammenhang mit Ausstattungsdaten, wenn mehrere Fahrzeuge betrachtet werden.

6.4.2. Fehlalarmrate

Die Detektionsrate gibt die Wahrscheinlichkeit an, mit der ein Algorithmus eine Störung innerhalb eines bestimmten Zeit- und Ortsintervalls erkennt. Man spricht dann auch von der **Sensitivität** des Algorithmus. Auf der anderen Seite interessiert auch, mit welcher Wahrscheinlichkeit Fehlalarme auftreten, d.h. mit welcher Wahrscheinlichkeit keine Störung vorliegt, wenn der Zustand Störung gemeldet wird.

In der Literatur finden sich sehr unterschiedliche Definitionen für die Bestimmung der Fehlalarmrate von stationären Verfahren. Grundsätzlich kann man dabei zwei Maße unterscheiden. Die ereignisbezogene Fehlalarmquote berechnet das Verhältnis der Anzahl der Fehlalarme zu der Anzahl der Alarme. Im Gegensatz dazu gibt die zeitbezogene Fehlalarmrate die Fehlalarme im Hinblick auf ein zeitliches Bezugsintervall an [HOOPS ET AL. 1999]. Sie ist also ein Maß für die absolute Häufigkeit von fehlerhaften Meldungen. Problematisch ist hier jedoch die Wahl des zeitlichen Bezugsintervalls. Oft wird dazu die Gesamtanzahl der Algorithmusauswertungen verwendet. Diese Definition wird bei QI ET AL. (2002) ebenfalls für mobile Daten verwendet. Dabei muss jedoch beachtet werden, dass unterschiedliche Algorithmen oft unterschiedliche Auswertintervalle haben oder ein Algorithmus an mehreren Messquerschnitten ausgewertet wird. Wenn letzteres der Fall ist, wird in der Regel eine normierte Fehlalarmrate berechnet und als Anzahl der Fehlalarme pro Zeitintervall pro Station angegeben. Eine etwas abgeänderte Definition findet sich bei THOMAS ET AL. (2001), die die Fehlalarmrate als die Anzahl der Zeitintervalle mit Fehlalarmen im Verhältnis zu der Anzahl der staufreien Zeitintervalle angeben.

Neben der Wahrscheinlichkeit, dass bei einer Meldung keine Störung vorliegt, kann die Wahrscheinlichkeit, dass ein Verfahren bei freiem Verkehr keine Störung meldet berechnet werden. Diese Größe wird in der Literatur als **Spezifität** bezeichnet. Sie spielt zusammen mit der Sensitivität eine wichtige Rolle bei der Bewertung von Kosten und Nutzen eines Tests [BOGENBERGER & KATES 2002]. Üblicherweise werden die beiden Größen in einem Koordinatensystem, der sog. ROC-Kurve, mit der x-Achse (1-Spezifität) und der y-Achse der Sensitivität aufgetragen. Dabei gilt, dass nicht beide Größen gleichzeitig optimiert werden können. Bei einer Erhöhung der Sensitivität wird ein Verfahren mehr Störungen erkennen. Gleichzeitig werden dabei mehr Störungen gemeldet, bei denen es sich nicht um Störungen handelt. Die Spezifität sinkt.

Die Spezifität kann aus der Fehlalarmrate berechnet werden, wenn zusätzlich noch die **Prävalenz** PR , die Wahrscheinlichkeit für das Auftreten einer Störung bekannt ist [GUGGENMOOS-HOLZMANN 1997].

$$\text{Spezifität} = 1 - \frac{PR}{1 - PR} \cdot \frac{FR}{1 - FR} \cdot \text{Sensitivität} \quad (6.1)$$

Gleichung 6.1 zeigt die Abhängigkeit der Spezifität von der Prävalenz. Bei dem hier verwendeten Versuchsdesign wird in jedem Simulationsszenario versucht, eine Störung zu erzeugen. Das hat zur Folge, dass eine hohe Prävalenz vorliegt, die Verfahren eine hohe Spezifität haben und die Fehlalarmrate sehr klein wird. Ein Fahrzeug verbringt einen Großteil seiner Zeit im Stau und wird mit geringer Wahrscheinlichkeit einen weiteren Stau erkennen. Eine ereignisbezogene Fehlalarmrate ist aus diesem Grund nicht sehr aussagekräftig und wird daher nicht verwendet. Es wird vielmehr die Dauer der Erkennung miteinbezogen.

Definition 6.3 [Fehlalarmrate] Die **Fehlalarmrate** FR gibt die Wahrscheinlichkeit an, dass eine gemeldete Störung zu einem Zeitpunkt t in der Realität nicht vorhanden ist.

$$FR = 1 - \frac{T_E}{T_M}$$

mit

T_M : Zeitdauer, für die eine Störung gemeldet wird

T_E : Zeitdauer, für die eine vorhandene Störung gemeldet wird




Abbildung 6.11.: Betrachtung der Streckenabschnitte für die Berechnung der Fehlalarmrate

In Abbildung 6.11 sind zwei Fahrzeugtrajektorien dargestellt. Beide Fahrzeuge detektieren fälschlicherweise eine Störung. Dieses Zeitintervalle sind blau eingefärbt. Die richtig erkannte Störung ist dagegen rot markiert.

Gleichung 6.1 verbindet Fehlalarmrate und Spezifität miteinander. Bei gleich bleibender Prävalenz und Sensitivität führt eine verringerte Spezifität zu einer Zunahme der Fehlalarmrate. Die Sensitivität und Fehlalarmrate hat dementsprechend den gleichen Informationsgehalt wie die Betrachtung der Sensitivität und der Spezifität und wird im Weiteren verwendet. Zu beachten ist jedoch folgendes: Üblicherweise sind Detektionsrate und Sensitivität identisch definiert. Dies gilt jedoch nicht für diesen Fall. Die der Fehlalarmrate entsprechende zeitbezogene Definition von Sensitivität berechnet die Wahrscheinlichkeit, dass eine Störung zu einem Zeitpunkt t erkannt ist. Das bedeutet wiederum, dass sich Fehlalarmrate und Detektionsrate, wie sie hier definiert sind, nicht entsprechen. Trotzdem werden beide in der ROC-Kurve dargestellt.

6.4.3. Optimierung und Bewertung von XFCD-Verfahren

Die Verfahren werden bezüglich der oben definierten Detektions- und Fehlalarmrate bewertet. Für die Berechnung der Gütekriterien eines Szenarios werden die Trajektorien aller XFCD-Fahrzeuge betrachtet und zu einer Aussage über die Güte des Szenarios aggregiert:

$$DR_{Gesamt, Ein} = \frac{\sum_{i=1}^{n_{Xfcd}} n_{E, Ein, i}}{\sum_{i=1}^{n_{Xfcd}} n_{F, Ein, i}} \quad \text{und} \quad DR_{Gesamt, Aus} = \frac{\sum_{i=1}^{n_{Xfcd}} n_{E, Aus, i}}{\sum_{i=1}^{n_{Xfcd}} n_{F, Aus, i}}$$

sowie

$$FR_{Gesamt} = 1 - \frac{\sum_{i=1}^{n_{Xfcd}} T_{E, i}}{\sum_{i=1}^{n_{Xfcd}} T_{M, i}}$$

Dabei gibt n_{Xfcd} die Anzahl der XFCD-Fahrzeuge an.

Sollen Aussagen über mehrere Szenarien gemacht werden, werden analog alle Fahrzeugtrajektorien betrachtet und aus den Einzelaussagen (z.B. Anzahl erkannter Störungseinfahrten) die Gesamtgüte berechnet.

Oft ist auch von Interesse, wie sich ein Algorithmus bei unterschiedlich stark ausgeprägten Störungen verhält. Als Kriterium dient in dieser Arbeit die Reisezeit, die für den Fahrer und Nutzer von Verkehrsinformationen ein wichtiges Entscheidungskriterium bei der Routenwahl darstellt. Die Stärke einer Störung wird im Folgenden als der durchschnittliche Verlust an Reisezeit $T_{RZverlust}$ definiert, den ein Fahrzeug bei Durchfahren einer Strecke erfährt. Sie berechnet sich folgendermaßen:

$$T_{RZverlust} = \frac{T_{RZgesamt} - T_{RZBasis}}{n_{Xfcd}}$$

wobei

$T_{RZgesamt}$: Gesamtreisezeit aller Xfcd-Fahrzeuge des Szenarios

$T_{RZBasis}$: Gesamtreisezeit aller Xfcd-Fahrzeuge für das störungsfreie Basis-Szenario

6.5. Referenzverfahren für die Bewertung von XFCD-Verfahren

Dieser Abschnitt stellt ein Referenzverfahren vor, das als Goldstandard für die Bewertung der XFCD-Verfahren verwendet wird. Die Bewertung erfolgt auf der Basis simulierter Daten. Das hat den Vorteil, dass alle Größen zu jedem Zeitpunkt t und an jedem Ort x bekannt sind, und als Referenz dienen.

6.5.1. Datenbasis

Bei der Untersuchung von Verfahren zur Erkennung von Verkehrsstörungen auf der Basis stationärer Daten werden in der Regel Störungen aus einer historischen Datenbank als Referenz verwendet. Diese Datenbank kann Daten über reale Störungen wie z.B. Unfälle, Baustellen etc. enthalten oder simulierte Verkehrsstörungen. Auf dieser Basis werden die Detektionsrate und die Fehlalarmrate berechnet. Hier ist das nicht möglich, da es nicht ausreicht, den Ort der Störungsursache zu kennen. Ein Fahrzeug kann eine Störung frühestens dann autonom erkennen, wenn es die Wirkung der Störung erfährt. Es ist also notwendig, ein Referenzverfahren zu entwickeln, das das Geschwindigkeitsfeld nicht nur zeitlich, sondern auch räumlich abtastet, um für jeden Simulationsschritt den Ort der Stoßwelle zu erkennen und wiederzugeben. Zu diesem Zweck werden in dieser Arbeit die Daten aller Fahrzeuge verwendet. Dies entspräche einer 100% Ausstattung an FCD-Fahrzeugen.

6.5.2. Vorgehensweise

Für die Bewertung der Verfahren ist es nicht notwendig, ein online-fähiges Verfahren zu entwickeln. Aus diesem Grund werden alle Szenarien der, in Abschnitt 6.3 dargestellten, Szenariendatenbank vorab simuliert, mit dem Referenzverfahren ausgewertet und abgespeichert.

Für jedes Szenario stehen zu jedem Zeitpunkt $t \in [0, t_{Simulation}]$ der Simulation Ergebnisdaten zur Verfügung. Für einen beliebigen Zeitpunkt t der Simulation ist es dann möglich, die räumliche Verteilung der Fahrzeuge und ihrer Geschwindigkeiten in einem Koordinatensystem aufzutragen. Ein Beispiel hierfür zeigt Abbildung 6.12. Jeder Punkt stellt ein Fahrzeug $i, i \in n_{Fahrzeuge}$ an einer Position x_i mit Geschwindigkeit v_i dar. Die Farbe des Fahrzeugs gibt die Spur an, auf der es sich befindet. Das Referenzverfahren durchläuft die Simulation und erzeugt zu jedem Zeitschritt einen Schnappschuss der Fahrzeuggeschwindigkeiten über den gesamten Streckenabschnitt.

Auf dieser Basis wird im Folgenden das Referenzverfahren beschrieben. Das Referenzverfahren unterscheidet neben gestauten auch instabile Bereiche, die nur eine kleinräumige Störung im Verkehrsablauf darstellen. Für jeden Schnappschuss werden nacheinander zwei Arbeitsschritte durchgeführt:

1. Identifikation und Festlegung der gestauten Bereiche und
2. Erkennung instabiler Bereiche.

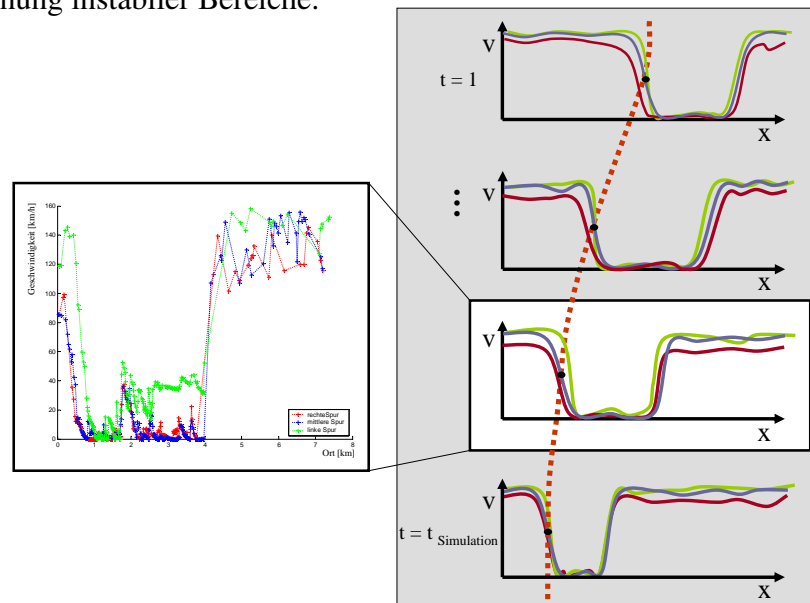


Abbildung 6.12.: Generierung von Geschwindigkeitsschnappschüssen für jeden Zeitschritt der Simulation

Identifikation und Festlegung der gestauten Bereiche durch das Referenzverfahren

Staus sind durch ein tiefes Geschwindigkeitsgefälle charakterisiert. Um einen Stau zu einem Zeitpunkt t zu identifizieren und den Ort des steilsten Geschwindigkeitsgradienten zu finden wird das Gebiet eingegrenzt, in dem eine hohe Geschwindigkeitsdifferenz stattfindet. Das Vorgehen wird am Beispiel der Einfahrt in eine Störung beschrieben (das Erkennen der Ausfahrt erfolgt analog).

Das Referenzverfahren soll die makroskopische Ausbreitung einer Staufront möglichst getreu widerspiegeln. Dazu ist es notwendig, das räumlich-zeitliche Geschwindigkeitsfeld darzustellen. Zu diesem Zweck wird die Simulation in zeitliche Schritte von 1s unterteilt und die Fahrzeugpositionen und ihre Geschwindigkeiten betrachtet (siehe Abb. 6.13). Zu beobachten ist, dass die Fahrzeugdichte vor und nach einer Staufront unterschiedlich ist und dass die Fahrzeugabstände nicht äquidistant sind. Um eine möglichst stabile Schätzung der Position bzw. der Ausbreitung der Staufront zu erhalten, wird nur eine, und nicht alle Spuren gleichzeitig betrachtet, da die Berücksichtigung aller Spuren zu einem großen Rauschen in der Position der Flanke führt. In dieser Arbeit wird davon ausgegangen, dass die zu informierenden Fahrzeuge keine Kenntnis über die Spur besitzen. Die mittlere Spur zeigt dabei die beste Repräsentanz. Auf der anderen Seite wird die räumliche Gestalt der Geschwindigkeitsverteilung analysiert.




Abbildung 6.13.: Identifikation von möglichen gestauten Bereichen: Die Kreuze geben die Geschwindigkeit der Fahrzeuge in Abhängigkeit von der Position auf einer zunächst beliebigen Spur an. Im abgebildeten Beispiel beginnt die Störung etwa bei Kilometer 1.7 und endet bei Kilometer 4.1.

Die Strecke wird Fahrzeug für Fahrzeug abgetastet. Jedem Fahrzeug werden die Attribute (Position, Geschwindigkeit, Spur) zugeordnet. Die Geschwindigkeiten der Fahrzeuge vor und nach dem Übergang in den Stau unterscheiden sich in ihren Mittelwerten. Unter der Annahme, dass Geschwindigkeiten normalverteilt und kontinuierlich sind, wird überprüft, ob sich die Differenz der Geschwindigkeitsmittelwerte aufeinander folgender Fahrzeugstichproben innerhalb ihrer Vertrauensgrenzen befindet. Dazu wird im Folgenden ein Fahrzeug i betrachtet, das sich auf Position x_i befindet und die Geschwindigkeit v_i besitzt. Weiter werden die Fahrzeuge j mit $j = i - n_{Stau}, \dots, i - 1, i + 1, \dots, i + n_{Stau}$ betrachtet und die Mittelwerte der n_{Stau} Fahrzeuge vor und nach Fahrzeug i berechnet.

$$\bar{v}_{l,i} = \frac{1}{n_{Stau}} \cdot \sum_{j=i-n_{Stau}}^{i-1} v_j \quad \text{und} \quad \bar{v}_{r,i} = \frac{1}{n_{Stau}} \cdot \sum_{j=i+1}^{i+n_{Stau}} v_j$$

Die Zahl n_{Stau} ist dabei noch unbestimmt und wird im Folgenden als Fenstergröße bezeichnet. Die Streuung s_i der Geschwindigkeiten des ungestörten Verkehrs wird nach Gleichung 6.2 geschätzt.

$$s_i^2 = \frac{1}{n_{Stau} - 1} \cdot \sum_{j=i-n_{Stau}}^{i-1} (v_j - \bar{v}_{l,i})^2 \quad (6.2)$$

Unterscheiden sich die Mittelwerte $\bar{v}_{l,i}$ und $\bar{v}_{r,i}$ signifikant, ist ein Übergangsbereich erkannt.

$$|\bar{v}_{l,i} - \bar{v}_{r,i}| > \frac{s_i}{\sqrt{n_{Stau}}} \cdot F$$

Dabei ist F das Quantil der t-Verteilung der zunächst noch zu bestimmenden Irrtumswahrscheinlichkeit.

Aufgrund der hohen Empfindlichkeit des Tests ist eine sinnvolle Wahl der Fenstergröße n_{Stau} wichtig. Zu diesem Zweck wird eine Parametervariation durchgeführt und die Auswirkung unterschiedlicher Fenstergrößen untersucht. Die Auswertung basiert auf zwei Testszenarien. Jedes Szenario wurde für 2700 Sekunden auf der Evaluationsstrecke simuliert. Durch eine Spursperung von 15 Minuten bei Kilometer 4.05 wurde jeweils ein Stau verursacht und dafür die Zeitpunkte und Positionen der Stauflanken berechnet.

Bei der Wahl der Fenstergröße werden zwei Ziele verfolgt. Das Referenzverfahren soll nur real auftretende Stauflanken, also Änderungen zwischen freiem und gestautem Verkehr, erfassen und keine Meldungen bei freiem Verkehr generieren. Außerdem soll die erkannte Stauflanke nicht verrauscht sein. Erfasste Störungen, die zu weit von der makroskopischen Stauflanke entfernt sind, werden hier ebenfalls als fehlerhaft bewertet. Daher wird als erstes Kriterium die Anzahl der Fehlalarme betrachtet. Auf der anderen Seite sollen alle Stauflanken auch wirklich erkannt werden. Das zweite Kriterium prüft daher die Gesamtanzahl der erkannten Übergänge. Zur Bestimmung der besten Fenstergröße wird eine Routine erstellt, die diese Kriterien für die zwei Versuchszenarien auswertet. Aufgrund der mangelnden Referenz, die hier erst entwickelt wird, erfolgt die Auswertung teilweise manuell, d.h. es werden einige Informationen wie Stauanfang und Stauende vorgegeben.

Fenstergröße n_{Stau}	10	20	30	40	50
Fehlalarme	596	392	34	42	268
Erkannte Flanken	1589	1797	2155	2147	1921

Tabelle 6.5.: Ergebnis der Parametervariation für die Staueinfahrt

Das Ergebnis für die Staueinfahrt ist in Tabelle 6.5 dargestellt. Es zeigt sich deutlich, dass die Anzahl der fehlerhaften Meldungen mit zunehmender Fenstergröße erst abnimmt und dann wieder ansteigt. Analog nimmt die Anzahl der erkannten Störungseinfahrten zuerst zu und dann wieder ab. Grund ist, dass eine Erhöhung der Fenstergröße anfangs zu einer stärkeren Glättung und damit zu einer robusteren Erkennung führt, bei der nur starke Geschwindigkeitseinbrüche erkannt werden. Wird die Fenstergröße jedoch zu groß werden nicht mehr alle Geschwindigkeitseinbrüche zeitnah erfasst.

Stauausfahrten weisen im Vergleich zu Staueinfahrten häufig eine breitere Form auf. Die Beschleunigung erfolgt auf einer ausgedehnten Strecke. Das bewirkt eine schlechtere Erkennung bei einer sehr kleinen Fenstergröße wie $n_{Stau} = 10$ (siehe Tabelle 6.6). Dort werden zum einen wenige Geschwindigkeitsanstiege erkannt, zugleich aber im Vergleich zu anderen Fenstergrößen sehr viele Fehlermeldungen erzeugt. Wie bei der Staueinfahrt nimmt die Anzahl der Fehlermeldungen erst ab und dann wieder zu. Auch die Anzahl der erkannten Flanken steigt anfangs und nimmt dann leicht ab.

Fenstergröße n_{Stau}	10	20	30	40	50
Fehlerhaften Meldungen	862	516	135	111	372
Erkannte Flanken	1335	1685	2066	2087	1829

Tabelle 6.6.: Ergebnis der Parametervariation für die Stauausfahrt

Die Ergebnisse aus Tabelle 6.5 und Tabelle 6.6 zeigen deutlich, dass $n_{Stau} = 30$ und $n_{Stau} = 40$ die besten Ergebnisse liefern. Um eine robustere Erkennung zu gewährleisten wird $n_{Stau} = 40$ verwendet. Als Quantil der t-Verteilung wird $F = 3.5$ gewählt. Dies entspricht einer Mindestfensterlänge von $n \approx 23$ und einer Irrtumswahrscheinlichkeit von etwa $\alpha = 0.001$.

Es wird außerdem gefordert, dass bei einer Störung, für die der Test anschlagen soll, die Geschwindigkeit mindestens unter einen Schwellenwert v_{grenz} fallen muss:

$$v_i < v_{grenz}$$

Diese wird zu $v_{grenz} = 40 \frac{km}{h}$ bestimmt. Im Bereich des Staus wird weiter gefordert, dass mindestens 25 Fahrzeuge auf der mittleren Spur mit $v < v_{grenz}$ fahren. Die Staulänge zu einem Zeitpunkt t wird unter dieser Annahme für ein typisches Fundamentaldiagramm zu 700m geschätzt.

Das Referenzverfahren meldet mehrmals ein Geschwindigkeitsgefälle bzw. Geschwindigkeitsanstieg längs der Strecke bis ein neues Geschwindigkeitsniveau erreicht ist. Es entsteht daher ein Bereich einer Stauaufahrt $[x_{Ein,1}, x_{Ein,2}]$ bzw. einer Stauausfahrt $[x_{Aus,1}, x_{Aus,2}]$. Für diese soll jeweils eine einzelne Position die Stauflanke charakterisieren.

Wenn man sich vorstellt, dass ein typischer Zustandsübergang wie ein Teil einer Sinuswelle aussieht, kann man davon ausgehen, dass der steilste Punkt innerhalb von $[x_{Ein,1}, x_{Ein,2}]$ bzw. $[x_{Aus,1}, x_{Aus,2}]$ liegt. Um eine stabile Schätzung zu erhalten, wird die Position des Gradienten durch den Median dieser Bereiche festgelegt und mit x_{Ein} bzw. x_{Aus} bezeichnet.

Erkennung instabiler Bereiche durch das Referenzverfahren

Nach der Prüfung auf Stau untersucht das Referenzverfahren die Strecke auf instabile Bereiche. Diese zeichnen sich durch Geschwindigkeitsgefälle auf ein mittleres Geschwindigkeitsniveau aus und beeinflussen nur einen kleinräumigen Bereich (siehe Abb. 6.14). Dieser Zustand löst sich nach kurzer Zeit wieder auf oder geht in einen Stau über. Bei diesem Zustand handelt es sich nicht mehr um freien Verkehr; er ist jedoch nicht zu verwechseln mit den niedrigen Geschwindigkeiten bei Stau. Wie bei der Identifikation von gestauten Bereichen werden pro Zeitschritt Schnappschüsse erzeugt und die Geschwindigkeiten der Fahrzeuge über die Strecke betrachtet.




Abbildung 6.14.: Identifikation instabiler Bereiche: Diese sollen nicht als Stau erfasst werden.

Im Gegensatz zu einem Stau, bei dem das Fahrzeug abbremst und sich über längere Zeit auf einem niedrigen Geschwindigkeitsniveau bewegt, beschleunigt das Fahrzeug nach kurzer Zeit erneut. Es wird also ein Geschwindigkeitsverlauf gesucht, der scharf abfällt und kurz darauf wieder sein früheres Niveau erreicht. Sei i ein Fahrzeug, das sich auf Position x_i befindet und die Geschwindigkeit v_i besitzt. Weiter wird die Gruppe der $2n_{instabil}$ Fahrzeuge um Fahrzeug i betrachtet. Für diese Fahrzeuge gilt: $j = i - n_{instabil}, \dots, i - 1, i + 1, \dots, i + n_{instabil}$ ($n_{instabil} \ll n_{Stau}$). Außerdem werden $4n_{instabil}$ Fahrzeuge vor und nach dieser Gruppe betrachtet und für beide das mittlere Geschwindigkeitsniveau berechnet.

$$\bar{v}_{in,i} = \frac{1}{2n_{instabil} + 1} \cdot \sum_{j=i-n_{instabil}}^{i+n_{instabil}} v_j$$

$$\bar{v}_{außen,i} = \frac{1}{4n_{instabil}} \cdot \left(\sum_{j=i-3n_{instabil}}^{i-n_{instabil}-1} v_j + \sum_{j=i+n_{instabil}+1}^{i+3n_{instabil}} v_j \right)$$

Für den Signifikanztest wird die Varianz der Fahrzeuggeschwindigkeiten innerhalb des vermeintlich gestörten Gebiets benötigt.

$$s_{in,i}^2 = \frac{1}{2n_{instabil}} \cdot \sum_{j=i-n_{instabil}}^{i+n_{instabil}} (v_j - \bar{v}_{in,i})^2$$

Ein instabiler Bereich ist jedoch nur erkannt, wenn sich die Mittelwerte \bar{v}_{in} und $\bar{v}_{au\ddot{a}u\text{en}}$ signifikant unterscheiden

$$|\bar{v}_{in,i} - \bar{v}_{au\ddot{a}u\text{en},i}| > \frac{s_{in,i}}{\sqrt{2n_{instabil} + 1}} \cdot F$$

und wenn mindestens 15 Fahrzeuge einer Spur betroffen sind. Weitere Voraussetzungen sind das Unterschreiten der Geschwindigkeit des aktuell betrachteten Fahrzeugs i unterhalb eines Schwellenwerts. Dieser wird auf $70 \frac{km}{h}$ gesetzt. Da kleinräumige Störungen erkannt werden sollen, muss eine geringe Fensterbreite gewählt werden. Aus diesem Grund wird die halbe Fensterbreite auf $n_{instabil} = 5$ und das Quantil der t-Verteilung auf $F = 4$ gesetzt.




Abbildung 6.15.: Überlagerung des Referenzverfahrens auf einem Trajektorienplot

Nach dem Durchlaufen des Referenzverfahrens bis zum Simulationende $t_{Simulation}$ liegen die erfassten Stauflanken und instabilen Bereiche vor. Abbildung 6.15 zeigt ein exemplarisches Ergebnis. Im visuellen Vergleich zeigt das oben vorgestellte Referenzverfahren eine gute und sehr genaue Erkennung der Stauflanken bei größeren gestauten Bereichen. Bei kleineren Verkehrseinbrüchen oder teilweise niedrigen Verkehrsstärken ist die Abgrenzung im räumlich-zeitlichen Zusammenhang verrauscht. Falls sich, wie beispielsweise bei der Entstehung einer Störung, kaum Fahrzeuge stromabwärts der Störung befinden, werden für den Mittelwertvergleich positionsmäßig weit entfernte Fahrzeuge verwendet. Die Folge ist eine stromabwärtige Verschiebung der Stauflanke. Deshalb ist es zweckmäßig, die Abgrenzungen des räumlich-zeitlichen Gebiets nach folgender Glättung zu definieren: Die Flanke soll über mehrere Zeitintervalle geglättet werden. Positionsmäßig weit entfernt, erfasste Stauflanken werden zunächst in das Gebiet der Stauflanke zurückgesetzt. Ein gleitender Mittelwert über 35 Sekunden soll eine stabile und glatte makroskopische Stauflanke erzeugen.

6.6. Emulationsumgebung

Nachfolgend wird die Emulationsumgebung kurz beschrieben. In ihr werden die simulierten Daten in geeigneter Form für die Störungserkennung aufbereitet. Außerdem enthält sie die zu untersuchenden Erkennungsalgorithmen.

6.6.1. Allgemeine Datenverarbeitung

In Abbildung 6.16 wird die Datenverarbeitung von den simulierten Daten bis zu den Ergebnissen des Referenzverfahrens und der Verfahrensdurchläufe anhand eines Ablaufdiagramms dargestellt.

Am Ende der Simulation stehen zwei Ausgabedateien zur Verfügung. Die eine enthält die gesamten Ausgabedaten der nicht-ausgestatteten Fahrzeuge während die andere die Ergebnisse der XFCD-Fahrzeuge enthält. Aus diesen Ergebnisdateien werden die für das Referenzverfahren notwendigen Geschwindigkeits-, Positions- und Spur-Daten gefiltert und in einzelne Dateien abgespeichert. Die so entstandenen Textdateien werden fusioniert und in einer MATLAB-Datenmatrix sortiert nach Zeitschritten abgespeichert. Zu jedem Zeitpunkt sind dann für jedes Fahrzeug die Daten über Position, Spur und Geschwindigkeit enthalten. Diese Datenmatrix schafft die Datengrundlage für das Referenzverfahren.

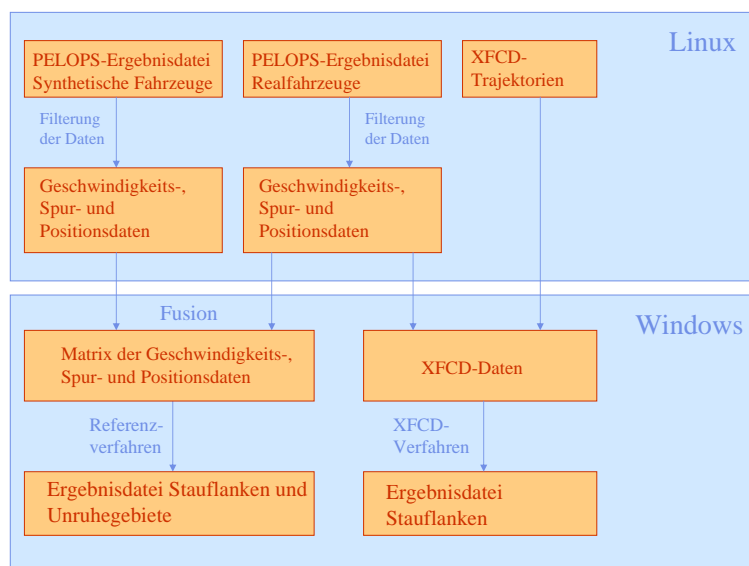


Abbildung 6.16.: Erzeugte Daten bei der Simulation mit PELOPS

Zusätzlich existiert pro XFCD-Fahrzeug eine Datei, die die aufgezeichneten XFCD-Daten enthält. Diese werden neben den bei der Filterung entstandenen Positionsdaten der Realfahrzeuge für die Evaluierung der XFCD-Verfahren genutzt.

Das Referenzverfahren und die XFCD-Verfahren speichern die Ergebnisse jedes Szenarios in Form von MATLAB-Dateien ab. Das in MATLAB implementierte Bewertungsverfahren liest diese ein und bewertet die Verfahren entsprechend der in Abschnitt 6.4 vorgestellten Methodik.

6.6.2. Durchlauf der XFCD-Verfahren

Die Verfahren zur Erkennung von Verkehrsstörungen sind in SIMULINK implementiert. Für die Bewertung werden alle XFCD-Fahrzeuge betrachtet. Es ist aber möglich, auch einzelne Fahrzeuge zu verfolgen. Die Störungserkennung über mehrere Fahrzeuge läuft automatisiert über eine kleine Routine. Beim Aufruf des SIMULINK-Modells bzw. der Routine wird der Anwender gebeten, den Pfad für das zu untersuchende Szenario anzugeben. Eine Funktion liest die Startpositionen und die durchfahrenen Positionen aller Fahrzeuge sowie die Simulationszeit und die Ausstattungsart ein.

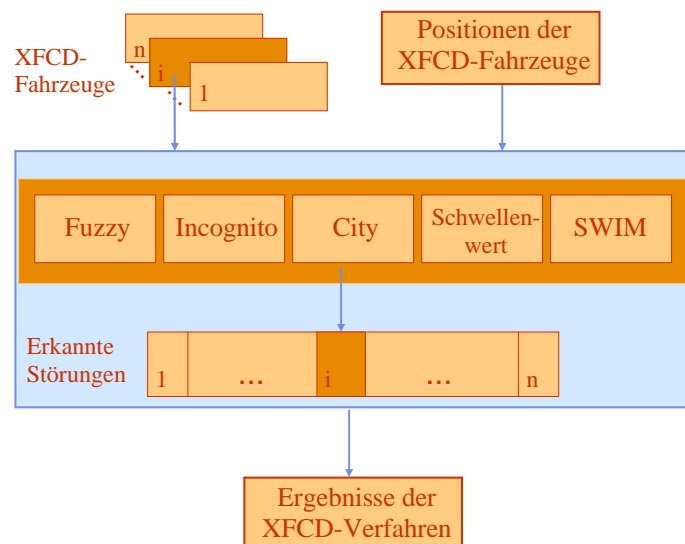


Abbildung 6.17.: Bewertungsumgebung

Anschließend werden die Fahrzeuge einzeln nacheinander betrachtet. Beim Start des SIMULINK-Modells werden die Parameter der Erkennungsverfahren initialisiert. Durch das Versuchsdesign festgelegte Parameter wie etwa die Straßenkategorie werden ebenfalls bereitgestellt. Weiter werden für das jeweils zu betrachtende Fahrzeug die XFCD-Daten eingelesen und für den Durchlauf aufbereitet. Dazu wird bestimmt, wann sich das Fahrzeug auf der Strecke befunden hat bzw. wann es aus dem Speicher auf die Strecke fährt und diesen wieder verlässt. Dies berücksichtigt, dass ein Fahrzeug mehrmals die Versuchstrecke durchfahren kann und verhindert, dass Speicheraufenthalte nicht fälschlicherweise als Störung erkannt werden.

Nach der Initialisierung folgt der „quasi“-online Durchlauf der Fahrt. Das SIMULINK-Modell liest pro Zeitschritt die XFCD-Daten ein. Die Daten werden online zu Kenngrößen verarbeitet und die Verfahren analysieren die Fahrt (siehe Abb. 6.17). Erkennt ein Verfahren ein Ereignis wird dies in einer dreidimensionalen Datenmatrix abgespeichert. Diese enthält für alle Verfahren und alle Fahrzeuge die Zeitpunkte der Erkennung und der Meldung einer Störungsein- bzw. Störungsausfahrt.

6.7. Optimierung der Parameter von SWIM

Dieser Abschnitt beschreibt die Bestimmung der Parameter von SWIM aus Tabelle 5.6. Die Optimierung erfolgt anhand eines genetischen Algorithmus. Dessen Struktur wird bezogen auf das vorliegende Problem kurz beschrieben. Für weiterführende Informationen wird auf die Literatur verwiesen (siehe u.a. [POHLHEIM 2000][HOLLAND 1975]).

6.7.1. Struktur des Genetischen Algorithmus

Genetische Algorithmen sind iterative, stochastische Suchverfahren. Sie orientieren sich an den Prinzipien der biologischen Evolution, indem sie diese stark abstrahiert algorithmisch nachbilden. Dabei wird eine Menge an Lösungen sukzessive durch Evolutionsoperatoren wie Selektion, Rekombination und Mutation verändert. Das Ziel ist es, eine bezüglich des Zielkriteriums höherwertige Lösung zu finden.

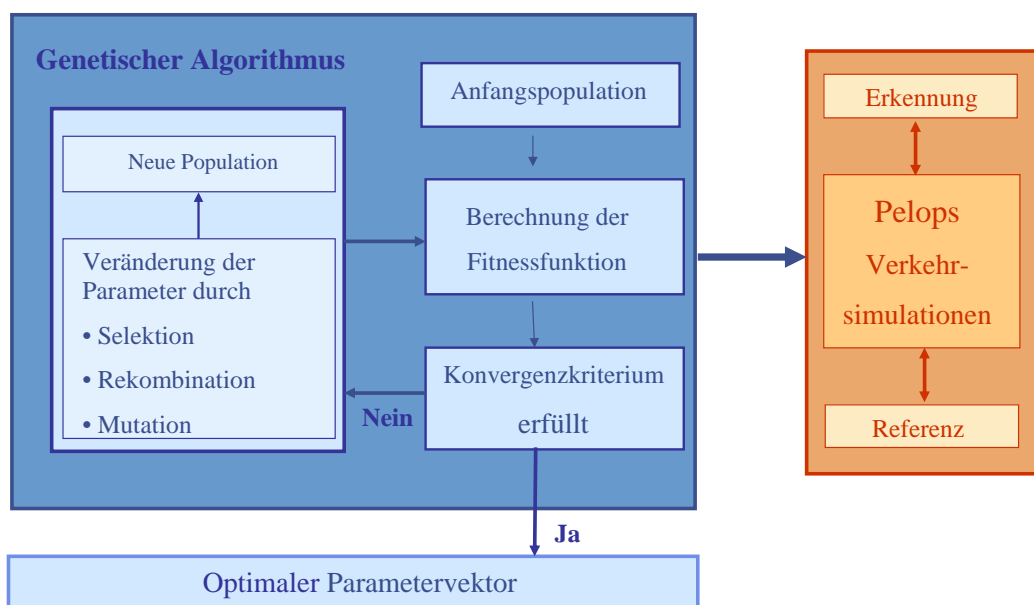


Abbildung 6.18.: Struktur des Genetischen Algorithmus

Im Gegensatz zu klassischen Optimierungsverfahren erfolgt die Suche parallel, da pro Iteration eine Population an Lösungen, den sog. Individuen, betrachtet wird. Jedes Individuum r stellt eine mögliche Parameterkombination für die Lösung des Problems dar. In diesem Fall besteht ein Individuum r aus einem Vektor der Länge 11, der die Parameter aus Tabelle 5.6 enthält. Statt der bei genetischen Algorithmen üblichen Binärkodierung werden hier reellwertige Vektoren verwendet. Die Güte von r wird anhand der Güte- oder Fitnessfunktion $F(r)$ bestimmt und soll sich im Laufe der Iteration dem optimalen Wert F nähern.

$$F = \max_{r \in \text{Individuen}} F(r)$$

Abbildung 6.18 stellt die Struktur des genetischen Algorithmus dar. Zu Beginn der Optimierung wird eine Anfangspopulation zufällig im Definitionsbereich der Parameter erstellt. Eine Funktion überprüft die Zulässigkeit der gewählten Parameterwerte.

Berechnung der Fitnessfunktion

Jedes Individuum der Population wird anhand seiner Fitness bewertet. Diese ergibt sich aus der Störungserkennung auf der Basis simulierter Daten. Für jede Parameterkombination wird der Algorithmus auf drei Lernszenarien mit jeweils 300 Fahrzeugen angewendet (siehe Abschnitt 6.3.2). Zwei der Szenarien stellen Stauszenarien dar während das dritte Szenario unruhigen Verkehr zeigt. Auf diesem Weg soll nicht nur eine Optimierung hinsichtlich einer hohen Erkennung erzielt werden, sondern auch eine minimale Fehlalarmrate erreicht werden.

Die Ergebnisse des Algorithmus werden mit dem Referenzverfahren verglichen und eine Güteberechnung gemäß Abschnitt 6.4 durchgeführt. Die Gesamtfitness eines Individuums ergibt sich dann zu

$$F(r) = \frac{1}{3} \cdot \sum_{j=1}^3 F_j(r)$$

Dabei stellt $F_j(r)$ die Fitness von Szenario j dar:

$$F_j(r) = \frac{1}{3} \cdot (DR_{Ein,j} + DR_{Aus,j} + (1 - FR_j)), \quad j \in 1, 2, 3$$

Die genetischen Operatoren Selektion, Rekombination und Mutation

Eine Population wird während der Optimierung durch genetische Operatoren von Generation zu Generation verändert. Die Optimierung endet hier, wenn eine bestimmte Anzahl an Generationen erreicht wird.

Die *Selektion* ist für die eigentliche Optimierung verantwortlich. Sie entscheidet, welche Individuen überleben. Dabei orientiert sie sich an der relativen Güte der Individuen. Durch stochas-

tische Auswahl haben auch Individuen mit geringer Fitness die Möglichkeit zu überleben. Im Laufe der Iteration werden sich jedoch die besten Individuen mit einer höheren Wahrscheinlichkeit durchsetzen. In dieser Arbeit wird die Roulette-Rad-Selektion angewendet. Dazu wird jedem Individuum ein Abschnitt eines normierten Roulettrades zugeordnet, der proportional zu seiner inversen Fitness ist. Eine gleichverteilte Zufallszahl wird generiert. Das Individuum, in dessen Abschnitt die Zufallszahl fällt, wird aus der Population entfernt.




Abbildung 6.19.: 2-Punkt-Rekombination

Die Rekombination und die Mutation sind für die Modifikation der Individuen zuständig. Bei der *Rekombination* werden die Informationen zweier Individuen verknüpft und ein neues Individuum erzeugt. Die Auswahl eines Elternpaares erfolgt in dieser Arbeit analog zur Roulette-Rad-Selektion aus den zuvor selektierten Individuen. Mit Hilfe zweier weiterer Zufallszahlen werden zwei Schnittstellen bestimmt, an denen die Teilstücke der Eltern ausgetauscht werden (siehe Abb. 6.19). Die neu entstanden Individuen werden der Population hinzugefügt.

Die restlichen Individuen der neuen Generation entstehen durch *Mutation*. Diese verhindert das Hängenbleiben in lokalen Maxima und sorgt für einen Erhalt der Artenvielfalt. Für die Mutation wird ein Individuum r der Population zufällig gewählt. Dann wird ein weiteres Individuum r' zufällig erzeugt. Der neue Nachkomme bildet den nach Mutationsrate gewichteten Mittelwert zwischen ausgewähltem und erzeugtem Individuum:

$$r_{neu} = (1 - \text{Mutationsrate}) \cdot r + \text{Mutationsrate} \cdot r'$$

Die Mutationsrate ist zu Beginn der Optimierung sehr groß gewählt, um eine zu frühzeitige Konvergenz des Algorithmus zu verhindern. Im Laufe der Iteration wird diese dann sukzessive verkleinert.

6.7.2. Ergebnis der Parameteroptimierung

Tabelle 6.7 zeigt die Randbedingungen für die durchgeführte Optimierung. Es werden 4 Läufe des genetischen Algorithmus mit durchschnittlich 11 Iterationen durchgeführt. Die Optimierungen zeigen jedoch keine klare Konvergenz. Vielmehr pendeln sich die Ergebnisse der Optimierung auf einem Niveau gleicher Fitness ein. Auch eine Erhöhung des Abbruchkriteriums auf 51 Iterationen führt zu keiner Verbesserung im Konvergenzverhalten. Dies mag

zum Teil an der relativ kleinen Populationsgröße liegen. Zu vermuten sind jedoch die widersprüchlichen Ziele in der gleichzeitigen Optimierung der Detektions- und Fehlalarmrate. Es ist typisch für multikriterielle Optimierungsprobleme, dass es nicht möglich ist, alle Ziele gemeinsam zu optimieren. Das Ergebnis ist vielmehr eine Front, längs derer die, bezüglich der Optimierungskriterien Detektions- und Fehlalarmrate, gleichwertigen Lösungen liegen.

Genetischer Algorithmus	Parameter
Anzahl Parameter	11
Populationsgröße	10
Sterberate	0.7
Rekombinationsrate	0.1
Mutationsrate	0.9

Tabelle 6.7.: Randbedingungen des Genetischen Algorithmus

Die Individuen mit den höchsten Fitnesswerten jeder Parameteroptimierung werden ausgewählt. Dabei zeigt sich deutlich, dass sich die Parametervektoren sehr stark unterscheiden. Es wird daher vermutet, dass die Parameter untereinander korreliert sind. Solche wechselseitige Abhängigkeit zwischen unabhängigen Variablen in einem Modell bezeichnet man auch als **Multikollinearität**. Eine Zusammenfassung der Parameter nach ähnlichen Parameterwerten zeigt aufgrund der hohen Dimension an Parametern keinen Zusammenhang. Würden weitere Kriterien hinzugezogen, könnten Methoden verwendet werden, die redundante Parameter erkennen und eliminieren. Stattdessen wird eine Clusteranalyse durchgeführt. Zu diesem Zweck werden für jeden Parameter ähnliche Parameterwerte zu Blöcken zusammengefasst und für jeden Block der Mittelwert gebildet. Die so entstandenen Parameterkombinationen werden den Ergebnissen der Optimierung hinzugefügt und untersucht. Die Clusteranalyse hat zum Ziel, ähnliche Ergebnisse zusammenzufassen und eine bessere Generalisierbarkeit zu erreichen. Die zugrunde liegende Idee ist, dass Parameterkombinationen, die sich im Inneren einer Punktwolke befinden, besser auf neue Daten reagieren als solche, die sich weit entfernt sind. Auf diesem Weg sollen weniger und stabilere Lösungen erhalten werden. Um diese Hypothese zu stützen, wurde auch mit unabhängigen Daten getestet und die Ergebnisse für gut befunden.

Als Verfahren wird das Clusterverfahren Fuzzy c-means (FCM) gewählt, für das eine Funktion in MATLAB zur Verfügung steht. FCM ist ein lokales, multidimensionales Optimierungsverfahren, das für jeden Datenpunkt den Zugehörigkeitsgrad zu jedem Cluster berechnet. Durch die Minimierung der über die Zugehörigkeit gewichteten Abstände der Datenpunkte zu den Zentren der Cluster erfolgt eine Verschiebung der Zentren in Richtung der tatsächlichen Mittelpunkte. Allgemein stellen die Ergebnisse der Clusteranalyse die Zentroide der Cluster dar. In diesem

Fall ergeben sich 9 Zentroide, deren Fitnesswerte verglichen und das beste Ergebnis gewählt wird (siehe Tabelle 6.8).

Bei Betrachtung der 9 Zentroide zeigt sich, dass sich die Parametervektoren insbesondere in den Werten von $T_{wartzeit}$ stark unterscheiden. Daher ist es von Interesse, die Empfindlichkeit der Qualität von SWIM und die Abhängigkeit von $T_{wartzeit}$, sowie dem mit ihm korrelierten Parameter $T_{verzögerung}$ zu untersuchen. Dies wird in Kapitel 7 durchgeführt.

Parameter		Modul	Ein-/Ausfahrt	Optimierung
$T_{Ein,1} = 110s$	$n_{Ein,1} = 120s$	M1	Einfahrt	a priori festgelegt
$T_{Ein,2} = 55s$	$n_{Ein,2} = 60s$	M1	Einfahrt	a priori festgelegt
$T_{Aus,1} = 50s$	$n_{Aus,1} = 200s$	M1	Ausfahrt	a priori festgelegt
$T_{Aus,2} = 75s$	$n_{Aus,2} = 130s$	M1	Ausfahrt	optimiert
$n_{Ausreisser} = 180s$		M2	Ein-/Ausfahrt	a priori festgelegt
$v_{\Delta stau} = 60 \frac{km}{h}$	$T_{stau} = 30s$	M3	Einfahrt	a priori festgelegt
$v_{\Delta instabil} = 47 \frac{km}{h}$	$T_{instabil} = 31s$	M3	Einfahrt	optimiert
$v_{\Delta aus} = 50 \frac{km}{h}$	$T_{aus} = 120s$	M3	Ausfahrt	a priori festgelegt
$a_{steil1} = 2 \frac{m}{s^2}$	$T_a = 10s$	M4	Einfahrt	a priori festgelegt
$a_{steil2} = 5 \frac{m}{s^2}$	$T_a = 10s$	M4	Einfahrt	a priori festgelegt
$v_{schwelle_im_stau} = 50 \frac{km}{h}$			Einfahrt	optimiert
$v_{schwelle_unruhe} = 74 \frac{km}{h}$			Einfahrt	optimiert
$T_{wartzeit} = 120s$			Einfahrt	optimiert
$T_{verzögerung} = 23s$			Einfahrt	optimiert
$v_{schwelle_kurzstau} = 15 \frac{km}{h}$			Einfahrt	optimiert
$v_{schwelle_frei} = 80 \frac{km}{h}$			Einfahrt	a priori festgelegt
$v_{schwelle_stau} = 45 \frac{km}{h}$			Ein-/Ausfahrt	optimiert
$T_{wartzeit_ausfahrt} = 25s$			Ausfahrt	optimiert

Tabelle 6.8.: Parameter der einzelnen Module von SWIM

7. Bewertung des Verfahrens SWIM – Ergebnisse

Das folgende Kapitel beschreibt die Bewertung des Verfahrens SWIM hinsichtlich der in Kapitel 6 vorgestellten Gütekriterien. Neben einer Sensitivitätsanalyse wird SWIM mit den XFCD-Verfahren aus Kapitel 4 verglichen. Zusätzlich wird eine Untersuchung auf Plausibilität mit Realdaten durchgeführt.

7.1. Bewertung des Verfahrens SWIM – Sensitivitätsanalyse

Das Verfahren SWIM wurde mit Hilfe der gemäß Kapitel 6 aufgebauten Szenariendatenbank untersucht. Die Bewertung erfolgt nach den dort vorgestellten Kriterien. Um Einflüsse an den Rändern der Simulationstrecke zu vermeiden wurde die Erkennung nur für den Streckenabschnitt zwischen den Kilometern 0.5 und 8.0 durchgeführt.

Kriterium	Parameter L1	Parameter L2	Parameter Z1
$v_{schwelle_stau}$	45	45	45
$v_{schwelle_im_stau}$	50	50	50
$v_{schwelle_unruhe}$	74	74	74
$T_{wartezeit}$	120	150	120
$T_{verzoegerung}$	10	15	23
$T_{wartezeit_ausfahrt}$	25	25	25
$v_{schwelle_kurzstau}$	15	15	15
$v_{\Delta 2}$	47	47	47
T_2	31	31	31
$n_{Aus,2}$	130	130	130
$T_{Aus,2}$	75	75	75

Tabelle 7.1.: Parametersätze für die Varianten L1, L2 und Z1

Die Ergebnisse der Parameteroptimierung in Kapitel 6 zeigten, dass der Parameterwert $T_{wartezeit}$ und damit auch $T_{verzoegerung}$ mit der größten Varianz behaftet sind. Daher ist es zweckmäßig, eine Sensitivitätsanalyse durchzuführen und die Empfindlichkeit von SWIM an neuen Szenarien zu testen. Dazu wird SWIM neben den aus der Optimierung gewonnen Parameterwerten (in diesem Abschnitt mit PA bezeichnet) in drei weiteren Varianten getestet (siehe Tabelle 7.1). Die Varianten werden im Folgenden mit L1, L2 und Z1 abgekürzt. Parametersatz L1 enthält einen kleineren Parameter $T_{verzoegerung}$. Dieser hat zur Folge, dass die Störungserkennung bei

sehr kleinen Geschwindigkeiten stärker verzögert wird. Bei Parametersatz L2 wird zusätzlich die Wartezeit bis zum Melden einer Störung erhöht.

Im Gegensatz zu den Parametersätzen L1 und L2 verwendet Z1 die in der Optimierung geschätzten Parameterwerte und berechnet stattdessen den Zeitpunkt der Erkennung getrennt von der eigentlichen Störungserkennung. Üblicherweise meldet SWIM den Ort der Störungseinfahrt zu dem Zeitpunkt, an welchem zum ersten Mal ein verändertes Geschwindigkeitsniveau erkannt wird. Z1 betrachtet von dort ein Zeitintervall in der weiteren Vergangenheit und berechnet in dem Zeitintervall den Median zwischen dem Maximum und dem Minimum der Geschwindigkeitswerte. Die zu diesem Zeitpunkt durchfahrene Position wird als Stauanfang bzw. Stauende gemeldet.

Zunächst werden die Detektions- und Fehlalarmrate des Verfahrens SWIM mit allen Varianten für die gesamte Szenariendatenbank vorgestellt. Im Anschluss wird SWIM in Hinblick auf unterschiedliche Anwendungsbereiche detailliert bewertet. Dabei werden zusätzlich zur gesamten Szenariendatenbank auch Szenarien getrennt nach der Art ihrer Störungsursache betrachtet. Dies soll eventuelle Stärken und Schwächen des Algorithmus in der Detektion aufdecken.

7.1.1. Detektionsrate und Fehlalarmrate von SWIM

Im Folgenden wird die Erkennung der Störungsein- und ausfahrten über alle 104 Szenarien der Szenariendatenbank dargestellt. Die Bewertung erfolgt in Abhängigkeit der zeitlichen und örtlichen Lokalisierung der Störung.

Detektionsrate der Störungseinfahrt von SWIM

Nach Kapitel 6 gilt die Einfahrt in eine Störung als korrekt erkannt, wenn das Verfahren sie innerhalb eines Zeitintervalls λ meldet und eine örtliche Differenz δ zwischen gemeldeter Störungsposition und aktueller Position der Stoßwelle nicht überschritten wird. Dazu werden verschiedene Schwellenwerte von λ und δ untersucht:

$$\begin{aligned}\lambda &= \{60, 90, 120, 150, 180, 240, 300\} [s] \\ \delta &= \{0.1, 0.2, 0.4, 0.8, 1.0, 1.5, 2.0\} [km]\end{aligned}$$

Die Detektionsrate gibt dann den Anteil der korrekt erkannten Störungen in Abhängigkeit von δ und λ an. Ihr Wert liegt somit im Bereich $[0; 1]$. Ein Wert von 1 bei einem δ_i und λ_i ($i \in 1, \dots, 7$) bedeutet somit, dass alle durchfahrenen Störungseinfahrten innerhalb der Schwellenwerte δ_i und λ_i korrekt erkannt werden.

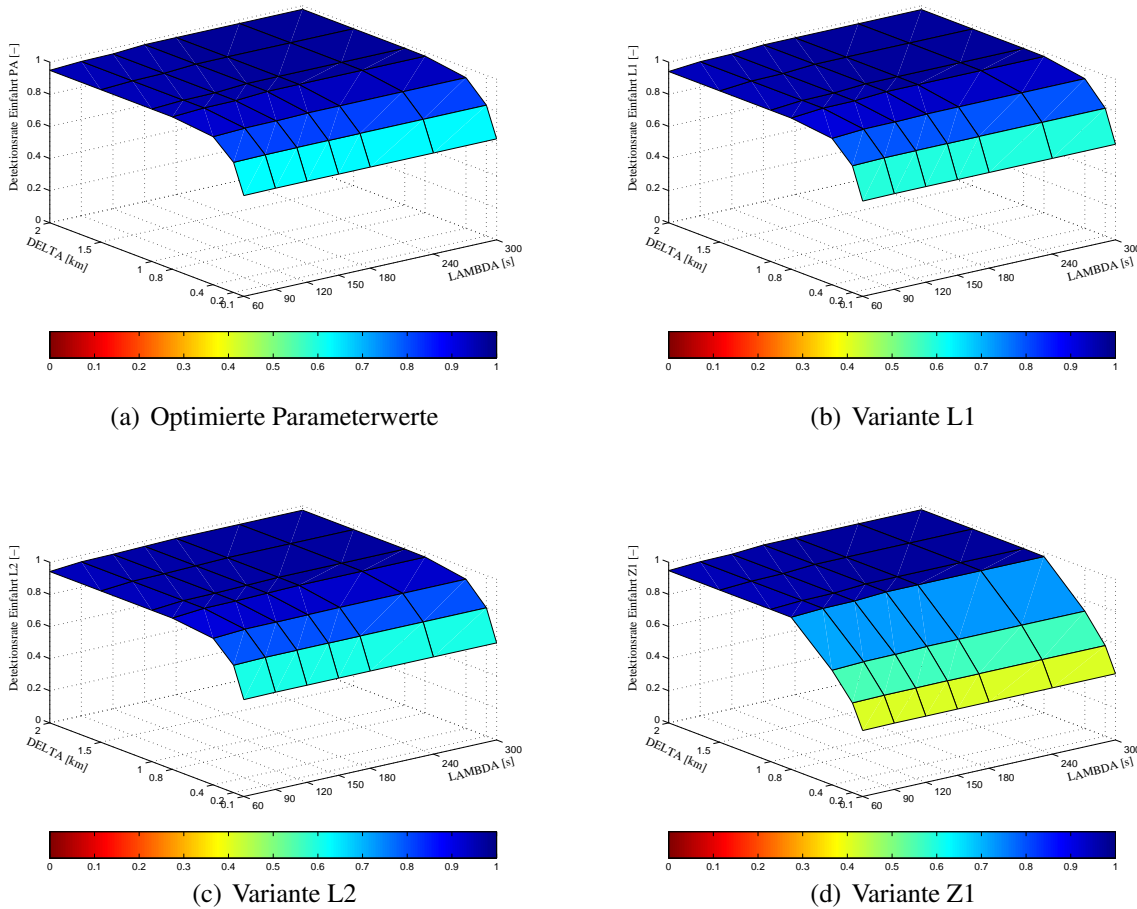


Abbildung 7.1.: Detektionsrate von SWIM für die Erkennung der Einfahrt in eine Störung. Als Basis dient die gesamte Szenariendatenbank.

Abbildung 7.1 zeigt die Detektionsrate für die Erkennung der Störungseinfahrt getrennt für jede untersuchte Variante von SWIM. Die Qualität der Erkennung ist sowohl räumlich als auch farblich dargestellt. Dunkelblaue Farbtöne markieren eine hohe Erkennungsrate. Die räumliche und zeitliche Verzögerung nimmt in Richtung der x - bzw. y -Achse zu. Wie zu sehen ist, ist die Erkennung bei allen Varianten ähnlich, speziell bei größeren, erlaubten örtlichen Verzögerungen. Das Verfahren erreicht innerhalb der untersuchten Schwellenwertgrenzen eine Detektionsrate von 97.7%.

Auffällig und erfreulich ist die geringfügige Änderung der Erkennungsgüte über λ , d.h. eine gute Erhaltung der Detektionsrate selbst über kleine Zeitintervalle λ . Ein Grund liegt in der Auslegung von SWIM auf eine zeitnahe Erkennung der Geschwindigkeitsgradienten. Der zweite Grund liegt in der anfangs sehr restriktiven Wahl von δ . Um diese zu unterschreiten ist eine sehr schnelle Meldung des Algorithmus notwendig. Denn je verzögerter eine Meldung erfolgt, desto weiter wird sich die Störung möglicherweise in Gegenrichtung fortgepflanzt haben. Nimmt man für die Stoßwelle beispielsweise eine Fortpflanzungsgeschwindigkeit von $4 \frac{m}{s}$ an, so

befindet sich nach 25s die Störungseinfahrt 100m stromaufwärts. Die örtliche Differenz steigt somit schnell mit einer verzögerten zeitlichen Detektion an.

Das Ergebnis von Variante Z1 im Bereich kleiner Werte von δ wird plausibel, wenn man berücksichtigt, dass Z1 die Zeitreihe vor dem eigentlichen Erkennungszeitpunkt durchsucht (siehe Abb. 7.1(d)). Es zeigt, dass auch die Betrachtung eines zu frühen Ausschnitts der Zeitreihe zum Verpassen der Staufront führen kann. Dies bestätigt eine genauere Betrachtung von Z1, bei der im Vergleich zu den anderen Varianten ein größerer negativer, örtlicher Versatz gemacht wird. Es bestätigt aber insbesondere auch die gute Lokalisierung der Einfahrtserkennung innerhalb von SWIM.

Detektionsrate der Störungseinfahrt von SWIM

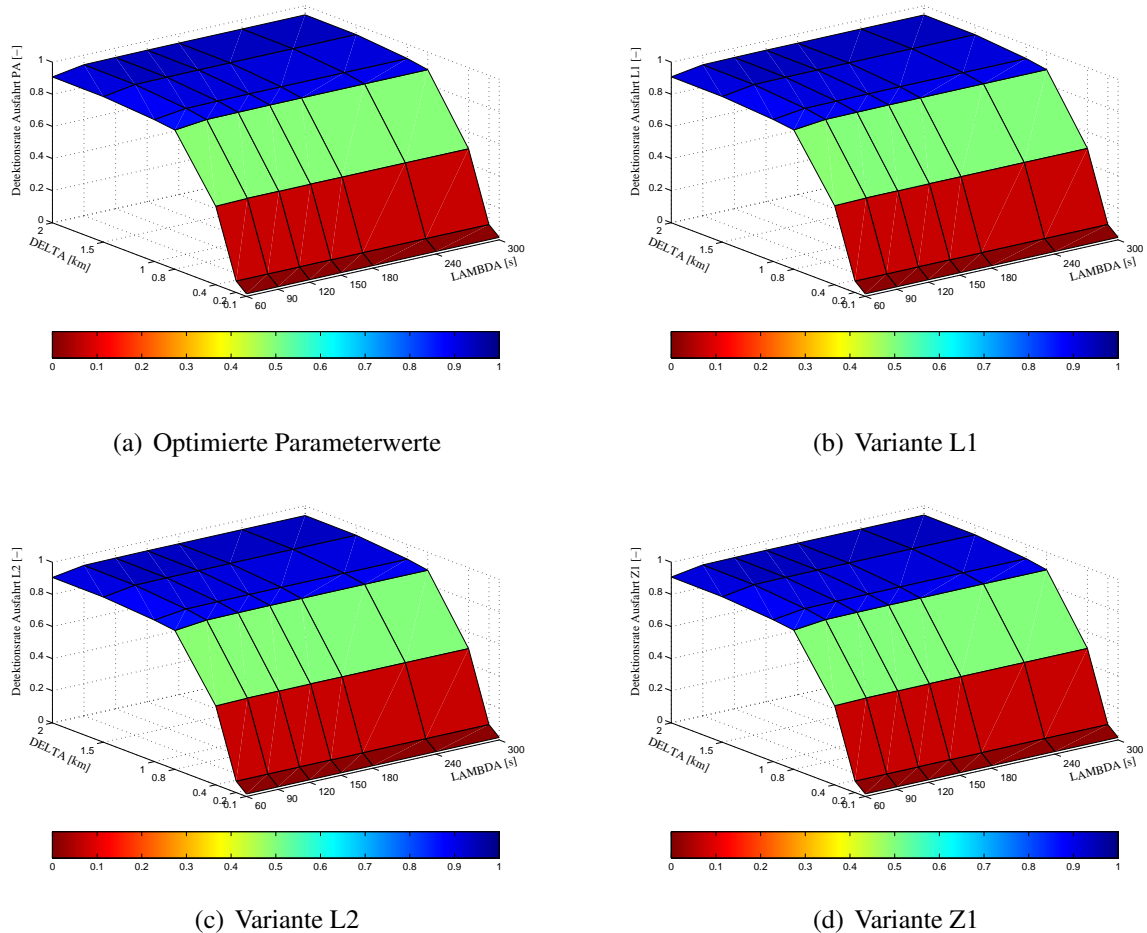


Abbildung 7.2.: Detektionsrate von SWIM für die Erkennung der Ausfahrt aus einer Störung. Als Basis dient die gesamte Szenariendatenbank.

Abbildung 7.2 zeigt analog die Detektionsrate von SWIM bei der Ausfahrt aus einer Störung. Die Ergebnisse der verschiedenen Varianten von SWIM zeigen ein übereinstimmendes Verhalten. Im Vergleich zur Störungseinfahrt erfolgt die Detektion örtlich stärker versetzt. Während

eine Störungseinfahrt in der Regel mit einem steilen Geschwindigkeitsgradienten verbunden ist, erstreckt sich der Geschwindigkeitsanstieg bei der Ausfahrt über eine längere Strecke; die Ausfahrt kann erst versetzt erkannt werden. Das betrachtete Zeitfenster bei Z1 ist im Vergleich zur Einfahrt adäquat gewählt, so dass in diesem Fall die Erkennung im Bereich der anderen Varianten liegt.

Bei der Bewertung der Ausfahrt ist allgemein zu beachten, dass ihre Detektionsrate nicht unabhängig von der Detektionsrate der Einfahrt ist. Es ist nur möglich eine Ausfahrt zu erkennen, wenn die entsprechende Einfahrt detektiert wurde. Trotzdem bezieht sich in dieser Arbeit die Detektionsrate der Ausfahrt auf die Gesamtanzahl der durchgefahrenen XFCD-Fahrzeuge und nicht nur auf die Untermenge der Fahrten mit erfolgreich erkannten Einfahrten.

Fehlalarmrate von SWIM

Die Robustheit eines Verfahrens ist ein weiteres wichtiges Kriterium bei der Beurteilung von Erkennungsalgorithmen. Schließlich soll der Fahrer nur Meldungen empfangen, wenn auch wirklich eine Störung vorliegt. Ein Zeichen für die Robustheit ist die Fehlalarmrate, die die Wahrscheinlichkeit für eine fehlerhafte Meldung angibt. Wie in Kapitel 6 besprochen, lässt sich eine ereignisbezogene Fehlalarmrate für dieses Versuchsdesign nur ungenau ermitteln. Diese müsste im Rahmen einer weiteren Untersuchung bzw. eines Feldtests bei einer gegebenen geringen Prävalenz ermittelt werden. Stattdessen wird die Fehlalarmrate zeitbezogen angegeben. Diese eignet sich besonders für Aussagen über die Qualität von Verkehrsmeldungen, da eine Störung im System so lange als vorhanden angesehen wird, bis ein Abmelden erfolgt.

Abbildung 7.3 zeigt die Detektionsrate gegenüber der Fehlalarmrate für die vier Varianten. Dabei stellt die Detektionsrate die Güte der Einfahrtserkennung für $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$ dar. Es zeigt sich, dass, trotz der Unterschiede zwischen PA und Z1, die Punkte in der Grafik sehr eng zusammen liegen.

Im Folgenden wird SWIM im Hinblick auf Anwendungen im Bereich vorausschauender Regler, der Lokalen Gefahrenwarnung und der allgemeinen Verkehrsinformation bewertet. Wie beschrieben wird, stellen die Anwendungen unterschiedliche Anforderungen an die Erkennung. So ist für die Verwendung vorausschauender Regler eine sehr gute örtliche Lokalisierung der Staufrent notwendig. Bei der Lokalen Gefahrenwarnung wird die Qualität hinsichtlich einer frühzeitigen Erkennung untersucht. Gegenüber diesen beiden zeit- und ortskritischen Diensten werden im Bereich für routenwahlorientierte Verkehrsinformation größere Verzögerungen in Kauf genommen. Die verwendeten und nachfolgend begründeten Schwellenwerte sind in Tabelle 7.2 zusammengefasst.

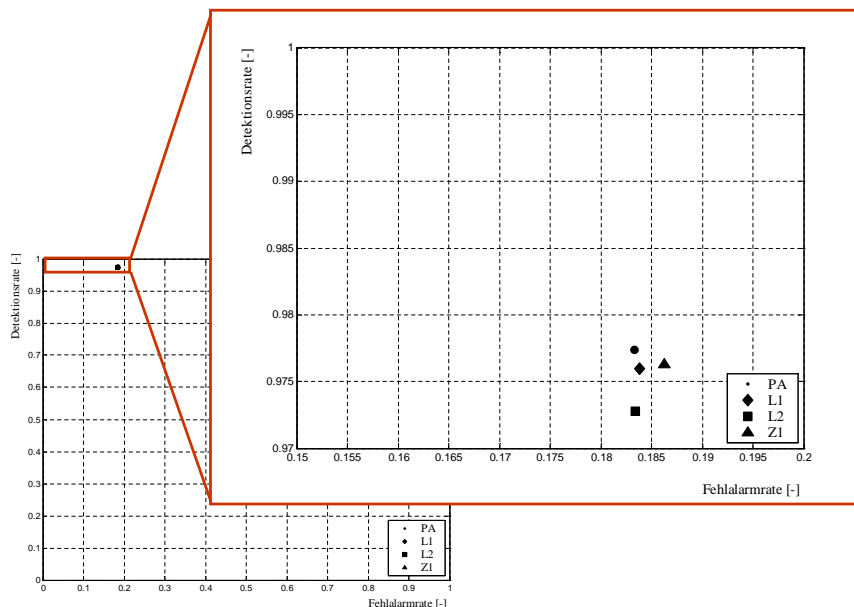


Abbildung 7.3.: Detektionsrate Einfahrt versus Fehlalarmrate

Anwendung	Einfahrt	Ausfahrt
Vorausschauende Regler	$\delta = 0.1\text{km}$ $60\text{s} \leq \lambda \leq 300\text{s}$	$\delta = 0.4\text{km}$ $60\text{s} \leq \lambda \leq 300\text{s}$
Lokale Gefahrenwarnung	$0.1\text{km} \leq \delta \leq 2.0\text{km}$ $\lambda = 90\text{s}$	
Routenwahl 1	$0.1\text{km} \leq \delta \leq 2.0\text{km}$ $\lambda = 120\text{s}$	$0.1\text{km} \leq \delta \leq 2.0\text{km}$ $\lambda = 120\text{s}$
Routenwahl 2	$0.1\text{km} \leq \delta \leq 2.0\text{km}$ $\lambda = 300\text{s}$	$0.1\text{km} \leq \delta \leq 2.0\text{km}$ $\lambda = 300\text{s}$

Tabelle 7.2.: Schwellenwerte λ und δ für die Untersuchung unterschiedlicher Anwendungsbe-
reiche

7.1.2. Anwendungen im Bereich vorausschauender Regler

Wie in Abschnitt 3.3.3 besprochen wurde, ist für zukünftige verkehrsadaptive Assistenzsysteme eine exakte Lokalisierung der Störung insbesondere dann von entscheidender Bedeutung, wenn Informationen über die Verkehrssituation von umgebenden Fahrzeugen gemeldet werden und in ein Regelsystem einfließen. Die Informationen können beispielsweise genutzt werden, um die Kapazität einer Straße zu erhöhen und den Verkehr zu stabilisieren. Bei ungenauer Angabe der Position der Stoßwelle und der Ausfahrt können Störungen jedoch nicht mehr gedämpft oder verhindert werden. Es kann im Gegenteil zu einem Aufschwingen der Instabilität oder einer Vergrößerung des Störungsausmaßes kommen.

Für vorausschauende Regler ist daher eine sehr gute örtliche Lokalisierung beider Fronten von Bedeutung. Aus diesem Grund wird die Detektionsrate der Einfahrt für einen erlaubten örtlichen Versatz von $\delta = 0.1\text{km}$ betrachtet (siehe Tabelle 7.2). Dies bedeutet, dass ein Schnitt in der 3D-

Betrachtung der Detektionsrate aus Abschnitt 7.1.1 bei $\delta = 0.1\text{km}$ vollzogen wird. Es zeigt sich, dass SWIM PA für diesen Wert von δ unabhängig von λ eine Detektionsrate von etwa 0.629 aufweist (Einzelergebnisse siehe Anhang). SWIM meldet somit 63% der durchfahrenen Einfahrten in einer Genauigkeit von 100m. L1 und L2 zeigen ein vergleichbares Ergebnis während Z1 nur etwa 41% der Einfahrten innerhalb von 100m erkennt.

SWIM wird für jede Störungsursache getrennt bewertet, um eventuell auftretende Unterschiede in der Detektionsrate in Abhängigkeit der Störungsursache aufzudecken. Es zeigt sich, dass die relativen Ergebnisse der Varianten von SWIM im Vergleich gleich bleiben. Bei Betrachtung der unterschiedlichen Szenarien weisen alle Varianten, auch PA (49.8%), bei Sperrung der linken Spur zunächst eine deutlich geringere Detektionsrate auf. Am höchsten ist die Rate für die Szenarien mit Sperrung der mittleren und rechten Spur (PA: 78.9%) sowie der linken und mittleren Spur (PA: 75.9%) (siehe Anhang). Untersucht man diesbezüglich die Stauentwicklung und -ausbreitung in PELOPS genauer, stellt man jedoch fest, dass sich Störungen mit Sperrungen einzelner Spuren sehr ungleichmäßig und teilweise unrealistisch ausbreiten. Dies gilt speziell für die Sperrung der linken Spur, bei der zu Beginn der Störung, die Fahrzeuge auf den Nachbarspuren mit vergleichsweise hohen Geschwindigkeiten vorbeifahren. Dies führt dazu, dass Fahrzeuge auf der linken Spur keine Möglichkeit zum Spurwechsel erhalten. Bei Sperrung der rechten Spur und insbesondere der mittleren Spur werden die benachbarten Spuren dann in höherem Maße beeinflusst. Ab einer Sperrung von zwei Spuren verläuft die Stauausbildung gleichmäßig.

Der Bereich der Ausfahrt erstreckt sich über eine längere Strecke. Aus diesem Grund wird für vorausschauende Regler ein Schwellenwert von $\delta = 0.4\text{km}$ angestrebt. Die Detektionsrate wird ebenfalls in Abhängigkeit von λ für alle vier Varianten von SWIM ausgewertet. Alle Varianten von SWIM detektieren knapp 50% der Störungsausfahrten innerhalb von 400m (siehe Anhang). SWIM erkennt erst bei Wiedererreichen des Geschwindigkeitsniveaus des freien Verkehrs eine Ausfahrt. Es ist daher möglich, dies bei einer Meldung zu berücksichtigen und einen früheren Erkennungszeitpunkt zu finden. Die Detektionsraten der Szenarien unterschiedlicher Störungsursache schwanken leicht. Es zeigt sich eine leicht bessere Erkennungsgüte bei Szenarien mit Sperrung von 2 oder 3 Spuren. Die geringste Detektionsrate erreichen Szenarien mit Sperrung der linken (40.9%) oder rechten Spur (42.6%).

7.1.3. Anwendungen im Bereich der Lokalen Gefahrenwarnung

Anwendungen im Bereich der Lokalen Gefahrenwarnung haben zum Ziel, nachfolgende Fahrer vor kommenden Gefahrenstellen zu warnen (siehe Abschnitt 3.3.3). Auch hier geht es darum, eine Information frühzeitig bereitzustellen. Im Gegensatz zu den oben angesprochen kleinräumigen Anwendungen ist die örtliche Genauigkeit nicht in dem Maße erforderlich. Entscheidend

ist stattdessen die zeitnahe Information für den Fahrer. Daher wird die Güte von SWIM auf die Erkennung der Einfahrt innerhalb von 90 Sekunden untersucht.

Die Varianten PA, L1 und L2 zeigen auch hier eine gleichwertige Erkennung (siehe Anhang). Dies bestätigt auch die getrennte Untersuchung nach Störungsursachen. SWIM PA meldet 62.9% aller Störungen innerhalb von 90s. Dabei wird ein örtlicher Fehler von unter 100m erreicht. Werden 200m Ungenauigkeit in Kauf genommen erhöht sich die Detektionsrate auf 81%, bei 400m auf 93%. Ab 0.8km örtlicher Differenz unterscheiden sich die Varianten nicht mehr. Die beste Detektionsrate bei $\delta = 0.1\text{km}$ zeigen die Szenarien mit Sperrung der mittleren und rechten Spur (78.9%), gefolgt von denen mit Sperrung der linken und mittleren Spur (75.9%). Die schlechteste Erkennung zeigt das Szenario mit Sperrung der linken Spur mit 49.8%.

7.1.4. Anwendungen für routenwahlorientierte Verkehrsinformation

Bei Verkehrsinformationen steht neben einer genauen Lokalisierung die Robustheit der Verfahren im Vordergrund. Jedoch sollte, um einen Vorteil gegenüber der Detektion an lokalen Messquerschnitten zu erzielen, eine Störung erkannt werden, bevor die Stoßwelle den nächsten Detektor erreicht. Geht man von einer sehr engen Detektorinstallation von 500m und einer Stoßwellengeschwindigkeit von $4\frac{m}{s}$ aus, müsste das Verfahren die Störung innerhalb von 125s melden. Für Anwendungen im Bereich von Strecken ohne Induktivschleifen sind Meldungen auch dann wertvoll, wenn sie innerhalb von 3min ankommen. Aus diesem Grund werden im Folgenden die Anforderungen hinsichtlich einer Verfeinerung bestehender engmaschiger Detektoren sowie der Erzeugung neuer Informationen untersucht. Speziell für letztere Anwendung stellt die robuste Erkennung die Hauptanforderung.

Ein wichtiges Kriterium bei der Analyse von Verfahren zur Störungserkennung ist ihre Güte bei unterschiedlich schweren Störungen. Diese resultieren in unterschiedlich hohen Reisezeiten und beeinflussen folglich stark die Routenwahl eines Fahrers. Aus diesem Grund soll die Darstellung von SWIM unter diesem Gesichtspunkt betrachtet werden. Die Stärke einer Störung ergibt sich durch den durchschnittlichen Reisezeitverlust $T_{RZ\text{verlust}}$ über die Strecke (siehe Abschnitt 6.4). Die durchschnittliche Reisezeit im ungestörten Fall beträgt dabei 351s. Für die Untersuchung werden drei Klassen unterschieden:

Klasse 1	Geringe Stärke oder kein Reisezeitverlust	$T_{RZ\text{verlust}} < 100\text{s}$
Klasse 2	Mittlere Stärke	$100\text{s} \leq T_{RZ\text{verlust}} < 300\text{s}$
Klasse 3	Hohe Stärke	$T_{RZ\text{verlust}} \geq 300\text{s}$

Tabelle 7.3 stellt die Einteilung der Szenarien in Abhängigkeit von der Position, der Dauer und der Ursache dar. Die schwersten Störungen liegen bei den Szenarien mit Einzelsperrungen vor, da dort die Sperrdauer am höchsten ist.

Die Detektionsraten der Einfahrt für die drei Stärkeklassen bei $\lambda = 120s$ ähneln im Verlauf den Detektionsraten aus Abschnitt 7.1.3. Der Vergleich zwischen den Stärkeklassen zeigt eine leicht bessere Detektion bei Szenarien geringer Stärke (siehe Tabelle 7.4 für SWIM PA sowie Anhang). Wie oben besprochen wurde verläuft im verwendeten Verkehrssimulator die Stauausbreitung bei Sperrungen der linken oder rechten Spur teilweise unrealistisch. Viele Fahrzeuge haben keine Möglichkeit eine Störung zu erkennen, da sie mit hohen Geschwindigkeiten an der Störung vorbeifahren. Dies spiegelt sich in einer scheinbar geringeren Detektionsrate bei schwereren Störungen, die sonst widersprüchlich erscheinen würde. Abgesehen davon zeigt es, dass SWIM vor allem auf die Charakteristik des Geschwindigkeitsabfalls und nicht auf die Stärke, also die Dauer, die ein Fahrzeug von einem Stau betroffen ist, reagiert.

Störungsursache	Dauer	Störungsposition												
		1	2	3	4	5	6	7	8	9	10	11	12	13
Sperrung rechte Spur	15min	1	2	1	2	2	2	3	2	3	2	2	3	3
Sperrung mittlere Spur	15min	2	3	2	2	2	2	2	3	2	2	3	2	2
Sperrung linke Spur	15min	2	2	2	3	3	2	2	3	3	2	3	2	2
Kapazitätsverengung	15min	1	1	1	1	1	1	1	1	1	1	1	1	1
Vollsperrung	5min	2	2	2	2	2	2	2	2	2	1	2	2	2
Sperrung mittl. und rechte Spur	5min	1	1	1	1	1	1	1	1	1	1	1	1	2
Sperrung linke und mittl. Spur	5min	1	1	1	1	1	1	1	1	2	1	1	1	1
Sperrung linke und rechte Spur	5min	1	1	1	1	1	1	1	1	1	1	1	1	1

Tabelle 7.3.: Einteilung der Stärkeklassen in Abhängigkeit von der Ursache, der Dauer und der Position der Störung (siehe Tabellen 6.2 und 6.3 der Untersuchungsmethodik)

δ	0.1km	0.2km	0.4km	0.8km	1.0km	1.5km	2.0km
Klasse 1	0.724	0.888	0.963	0.992	0.992	0.992	0.992
Klasse 2	0.647	0.83	0.946	0.974	0.974	0.974	0.974
Klasse 3	0.629	0.814	0.932	0.962	0.963	0.964	0.964

Tabelle 7.4.: Detektionsrate Einfahrt von SWIM PA für die Klassen 1,2 und 3 und $\lambda = 120s$

Bei der Ausfahrt weisen alle Varianten von SWIM gleichwertige Ergebnisse auf. Hier zeigt sich jedoch ab $\delta = 0.8km$ eine bessere Qualität der Erkennung bei Szenarien mit hohem Reisezeitverlust (siehe Tabelle 7.5 für SWIM PA sowie Anhang). Das kann damit erklärt werden, dass die Erkennung der Ausfahrt unabhängig von der Spurenverteilung erfolgt. Sie ist vielmehr abhängig von deutlich unterscheidbaren Geschwindigkeitsniveaus.

Die Detektionsraten in Abhängigkeit vom Schweregrad der Störung für $\lambda = 300s$ entsprechen denen für $\lambda = 120s$ (siehe Anhang). Dies verdeutlicht noch einmal die in Abschnitt 7.1.1 besprochene, schnelle Detektion von SWIM.

δ	0.1km	0.2km	0.4km	0.8km	1.0km	1.5km	2.0km
Klasse 1	0.038	0.117	0.539	0.867	0.881	0.911	0.915
Klasse 2	0.02	0.082	0.502	0.884	0.906	0.932	0.935
Klasse 3	0.016	0.071	0.494	0.89	0.911	0.939	0.942

Tabelle 7.5.: Detektionsrate Ausfahrt von SWIM PA für die Stärkeklassen 1,2 und 3 und $\lambda = 120s$

7.2. Vergleich von SWIM mit existierenden XFCD-Verfahren

Der folgende Abschnitt vergleicht das Verfahren SWIM PA mit den in Kapitel 4 vorgestellten XFCD-Verfahren. Diese werden im Folgenden kurz mit City, Schwellenwert, Incognito und Fuzzy bezeichnet. Wie im vorangegangenen Abschnitt wird zuerst der Verlauf der Detektionsrate in Abhängigkeit der zeitlichen Verzögerung λ und des örtlichen Versatzes δ und die Fehlalarmrate untersucht. Anschließend wird die Güte der Verfahren für die Bereiche vorausschauende Regler, Lokale Gefahrenwarnung und Verkehrsinformation beschrieben. Für die Bewertung gelten die oben eingeführten Schwellenwerte. Im Anschluss werden die Verfahren hinsichtlich ihrer Erkennung bei aufeinander folgenden Störungen betrachtet.


7.2.1. Vergleich der Detektionsraten und Fehlalarmraten

Abbildung 7.4 stellt die Erkennung der Störungseinfahrten in Abhängigkeit des örtlichen Versatzes δ und der zeitlichen Verzögerung λ dar. Die rote Farbgebung bei dem für den innerstädtischen Bereich konzipierten Verfahren City zeigt deutlich die hohe zeitliche Verzögerung der Meldung, die erst ab 240s möglich ist. Grund ist die fest kodierte Plausibilitätsprüfung von 200s, die Halte an Lichtsignalanlagen herausfiltern soll. Letztendlich erreicht City eine Detektionsrate von 40% (siehe Abb. 7.4(a)). Auch das Verfahren Schwellenwert erkennt sehr verzögert, kann aber bei $\delta = 2.0km$ und $\lambda = 300s$ 71% der Störungseinfahrten detektieren (siehe Abb. 7.4(b)). Jedoch werden Meldungen erst langsam ab $\lambda = 120s$ generiert. Dies liegt in der im Verfahren ebenfalls fest kodierten minimalen Wartezeit.


Eine schnelle Detektion ermöglicht dagegen das Verfahren Incognito, das wie auch Fuzzy eine hohe Detektionsrate für große Werte von λ und δ erreicht (bis zu 96.6% und 94.1%) (siehe Abb. 7.4(c) und 7.4(d)). Durch die Verwendung des Beschleunigungsrauschens reagiert Incognito sehr schnell auf Änderungen im Geschwindigkeitsverlauf.

Die Ergebnisse der Ausfahrtserkennung sind in Abbildung 7.5 dargestellt. Hier zeigen die Verfahren City, Schwellenwert und Incognito eine sehr geringe Güte. Allein Fuzzy weist ein zu SWIM nur leicht verzögertes und schwächeres Verhalten auf (siehe Abb. 7.5(d)). Dort wird wie bei SWIM ein Zeitreihenmodell zur Detektion verwendet.


City erreicht für die betrachteten Schwellenwerte eine Detektionsrate von 41%. Ein Vergleich mit der erreichten Detektionsrate der Einfahrt zeigt, dass City ab $\delta = 0.4\text{km}$ praktisch alle erkannten Einfahrten sehr schnell detektiert (siehe Abb. 7.5(a)). Der örtliche Fehler beruht auf der teilweise zu frühen Erkennung von City. So wird bei einer unruhigen Staufahrt, die Wechsel in den Beschleunigungen enthält, schon vor Stauende eine Ausfahrt erkannt. Grund sind die im Verfahren festgelegten Schwellenwerte, die speziell auf Geschwindigkeitsniveaus im innerstädtischen Bereich ausgelegt sind.




(a) Verfahren City



(b) Verfahren Schwellenwert




(c) Verfahren Incognito




(d) Verfahren Fuzzy

Abbildung 7.4.: Detektionsrate der Einfahrt der Verfahren City, Schwellenwert, Incognito und Fuzzy


Die fehlende Differenzierung von Erkennung und Meldung neben festen Plausibilitätszeiten führen bei Incognito zu einer sehr verzögerten Ausfahrtserkennung. Die Detektion beim Verfahren Schwellenwert verläuft analog zu der der Einfahrt.




(a) Verfahren City



(b) Verfahren Schwellenwert



(c) Verfahren Incognito



(d) Verfahren Fuzzy

Abbildung 7.5.: Detektionsrate der Ausfahrt der Verfahren City, Schwellenwert, Incognito und Fuzzy





Abbildung 7.6.: Detektionsrate der Einfahrt versus Fehlalarmrate

Der Zusammenhang von Detektions- und Fehlalarmrate soll das Verhalten der XFCD-Verfahren demonstrieren. Deutlich zu sehen ist, dass die Fehlalarmrate von City sehr klein ist, jedoch auch nur rund 40% der Störungen erkannt werden. Sehr hohe Detektionsraten für die Einfahrt zeigen die Verfahren SWIM, Fuzzy und Incognito, deren Erkennungen sehr empfindlich auf Ände-

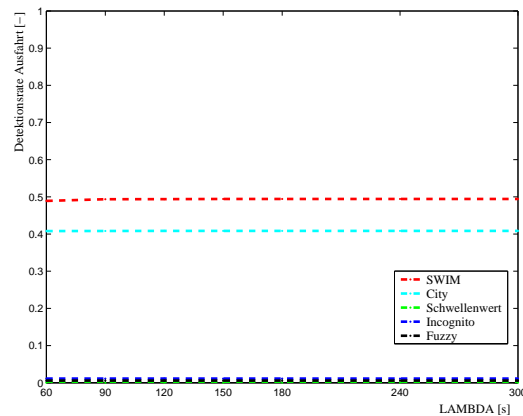
rungen im Geschwindigkeitsverlauf sind. Bei Incognito geht diese Empfindlichkeit jedoch mit einer erhöhten Fehlalarmrate einher. Diese ist auf die sehr empfindliche Kenngröße des Beschleunigungsrauschens zurückzuführen. Die etwas höhere Fehlalarmrate von Schwellenwert ist durch die sehr verzögerte Erkennung bedingt, die bewirkt, dass Meldungen länger im System der Verkehrszentrale enthalten sind und somit auch eine Erhöhung der Fehlalarmrate zur Folge haben.

7.2.2. Anwendungen im Bereich vorausschauender Regler

Im Bereich der kleinräumigen Störungserkennung werden die Schwellenwerte $\delta = 0.1\text{km}$ für die Erkennung der Einfahrt und $\delta = 0.4\text{km}$ für die Erkennung der Ausfahrt verwendet.



(a) Betrachtung der Einfahrt für $\delta = 100\text{m}$



(b) Betrachtung der Ausfahrt für $\delta = 400\text{m}$


Abbildung 7.7.: Vergleich der Detektionsrate für vorausschauende Regler

Bei der Einfahrt zeigt SWIM die beste Detektionsrate für die Gesamtszenariendatenbank (siehe Abb. 7.7(a)). Knapp 63% der Störungen werden mit einer Genauigkeit von 100m gemeldet. Dem folgt das Verfahren Incognito mit einer Erkennungsrate von 54.4%. City und Schwellenwert können wie zuvor gesehen innerhalb dieses Intervalls keine Störungen detektieren.


Bei einer Unterscheidung nach Störungsursachen schneidet das Szenario mit Sperrung der linken Spur wiederum am schwächsten ab (SWIM: 49.8%, Incognito: 44.2%). Insgesamt zeigen die Szenarien mit einer Sperrung eine schlechtere Erkennung. Die beste wird für SWIM, Incognito und Fuzzy bei der Sperrung der mittleren und rechten Spur erzielt.

Bei der Ausfahrt wird deutlich, dass nur die Verfahren City und SWIM in der Lage sind, Störungen innerhalb von 400m zu erkennen. Dabei zeigt SWIM gegenüber City eine bessere Detektionsrate bei Sperrungen von 2 – 3 Spuren während City besser Sperrungen einer einzelnen Spur detektiert. City erreicht bei Vollsperrung und bei zweispurigen Sperrungen nur ein Ergebnis von 28.9% bzw. um 15%. Ein Blick auf die Erkennung der Einfahrt zeigt jedoch, dass diese

Ergebnisse auf die dort erzielten Detektionsraten zurückzuführen sind. Die Güte der Ausfahrts-erkennung von City ist daher sehr gut; wenn eine Staueneinfahrt erkannt wurde, wird die Ausfahrt schon bei kleinen bis mittleren Werten von δ und λ detektiert.



(a) Betrachtung der Einfahrt für $\delta = 100\text{m}$



(b) Betrachtung der Ausfahrt für $\delta = 400\text{m}$

Abbildung 7.8.: Detektionsrate versus Fehlalarmrate für vorausschauende Regler. Die Punkte markieren den Fall $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$, die Quadrate den Fall $\lambda = 300\text{s}$ und $\delta = 100\text{m}$ bzw. $\delta = 400\text{m}$.

Abbildung 7.8 zeigt die für diese Anwendungen erreichten Detektionsraten gegenüber der Fehlalarmrate für die Ein- und Ausfahrt. Zum Vergleich sind die für die Einfahrt erreichten Detektions- und Fehlalarmraten für $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$ ebenfalls dargestellt.

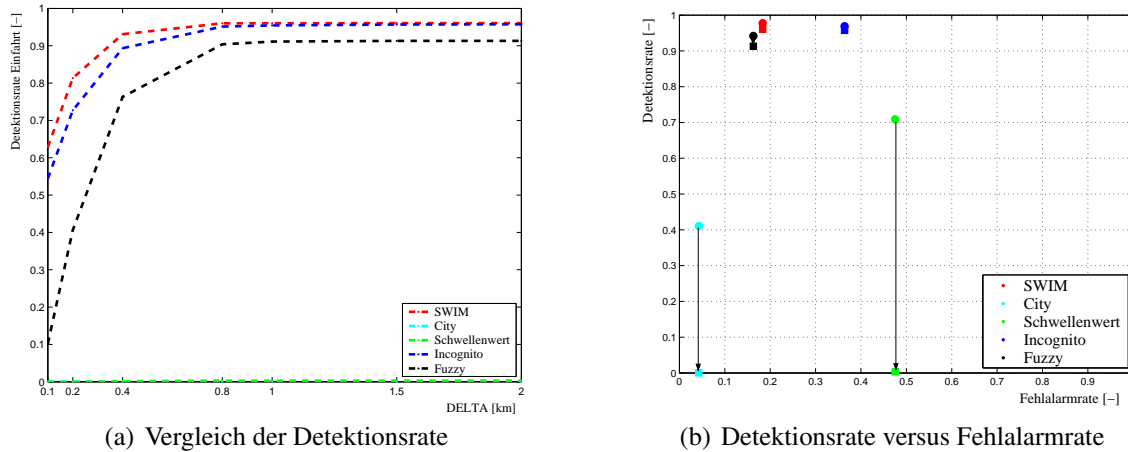
7.2.3. Anwendungen im Bereich der Lokalen Gefahrenwarnung

Im Bereich der Lokalen Gefahrenwarnung wird eine frühzeitige Erkennung innerhalb von $\lambda = 90\text{s}$ angestrebt. Der Verlauf der Detektionsrate des Gesamtszenarios in Abhängigkeit des örtlichen Fehlers δ ist in Abbildung 7.9(a) dargestellt.

Die Detektionsrate für die Störungseinfahrt steigt für die Verfahren SWIM, Incognito und Fuzzy ab $\delta = 0.4\text{km}$ bzw. $\delta = 0.8\text{km}$ stark an. Ebenso verhält es sich bei Szenarien unterschiedlicher Störungsursache. Keine Erkennung erfolgt hingegen bei City und SWIM. Diese Ergebnisse spiegeln sich in der Betrachtung der Detektions- und Fehlalarmraten wieder (siehe Abb. 7.9(b)). Schön zu erkennen ist wieder die schnelle Erkennung von SWIM als auch von Fuzzy und Incognito. Schon bei Schwellenwerten von $\lambda = 90\text{s}$ wird annähernd die Gesamtqualität erreicht.

Bei SWIM, wie auch trendmäßig bei Incognito und Fuzzy, ist erneut die beste Güte bei Szenarien mit mehrspurigen Sperrungen zu beobachten. Bei der Sperrung einzelner Spuren ist zu beobachten, dass SWIM für kleine δ die beste Güte aufweist, Incognito jedoch für größere δ

und Einzelsperrungen eine leicht bessere Erkennung zeigt, welche auf die größere Empfindlichkeit in der Detektion zurückzuführen ist. Bei mehrspurigen Störungen erzielt SWIM im Vergleich zu den anderen Verfahren die beste Qualität.



(a) Vergleich der Detektionsrate

(b) Detektionsrate versus Fehlalarmrate

Abbildung 7.9.: Detektions- und Fehlalarmraten für die Lokale Gefahrenwarnung bei Betrachtung der Einfahrt für $\lambda = 90s$. Abbildung 7.9(b) zeigt den Vergleich zwischen den Fällen $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$ (Punkte) und $\delta = 2.0km$ und $\lambda = 90s$ (Quadrate).

7.2.4. Anwendungen für routenwahlorientierte Verkehrsinformation


Wie in Abschnitt 7.1.4 beschrieben, werden für routenwahlorientierte Verkehrsinformationen zwei Anwendungen betrachtet. Bei vorhandener, engmaschiger Infrastruktur soll eine Verbesserung der Verkehrsinformationen erreicht werden; bei Strecken ohne Detektoren ist eine robuste Erkennung gefragt.

Verbesserung von Informationen bei dichten Detektorabständen


Abbildung 7.10 zeigt exemplarisch die Detektionsraten der Einfahrt und der Ausfahrt für Störungen geringer Stärke für $\lambda = 120s$. Die Ergebnisse der anderen Klassen sind im Anhang abgebildet. SWIM und Incognito erreichen schon bei einem örtlichen Versatz von $\delta = 0.1km$ bzw. $\delta = 0.2km$ Detektionsraten von über 50%, die mit steigendem δ weiter steil ansteigen (siehe Abb. 7.10(a)). Fuzzy beginnt dahingegen etwas verzögert, die Detektionsrate steigt aber ab $\delta = 0.2km$ steil an.

Der visuelle Vergleich der Detektionsraten der Einfahrt in Abhängigkeit der drei Stärkeklassen zeigt, dass SWIM, Incognito und Schwellenwert geringfügig niedrigere Detektionsraten bei schweren Störungen (Klasse 3) haben (siehe Abb. 7.11(a)). Dies ist hauptsächlich auf die Stauausbreitung im Verkehrssimulator zurückzuführen (siehe Abschnitt 7.1.2). Dagegen nehmen die

von Fuzzy mit zunehmender Stärke eher zu. Die erhöhte Fehlalarmrate bei Störungen geringerer Stärke ist hauptsächlich durch die verzögerte Erkennung bedingt, die sich bei Störungen geringerer Stärke in Relation zur Verweildauer im Stau größer auswirkt.



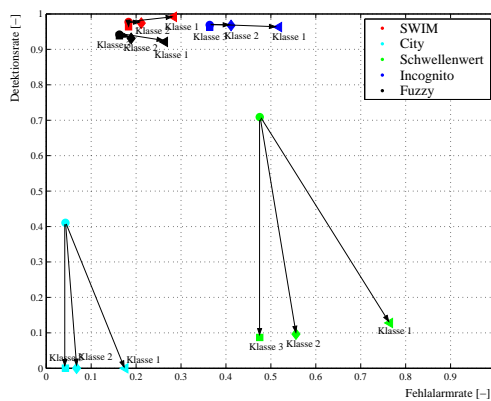
(a) Betrachtung der Einfahrt




(b) Betrachtung der Ausfahrt

Abbildung 7.10.: Vergleich der Detektionsrate für Störungen der Stärkeklasse 1 für $\lambda = 120s$

Bei der Betrachtung der Ausfahrt in Abhängigkeit von δ weisen SWIM einen steilen Güteanstieg ab $\delta = 0.2km$ und Fuzzy ab $\delta = 0.4km$ auf (siehe Abb. 7.10(b)). Dabei wird eine leicht bessere Güte bei schweren Störungen erzielt (siehe Abb. 7.11(b)). Allein City zeigt eine stark verbesserte Erkennung bei Störungen der Stärke 3 auf, welche insgesamt durch die bessere Detektion von Störungen der Klasse 3 bei der Einfahrt bedingt ist. Dies ist insbesondere im Vergleich der Detektionsrate im Vergleich zur Detektionsrate des gesamten Szenarios bei $\lambda \rightarrow \infty$ und $\delta \rightarrow \infty$ zu erkennen.



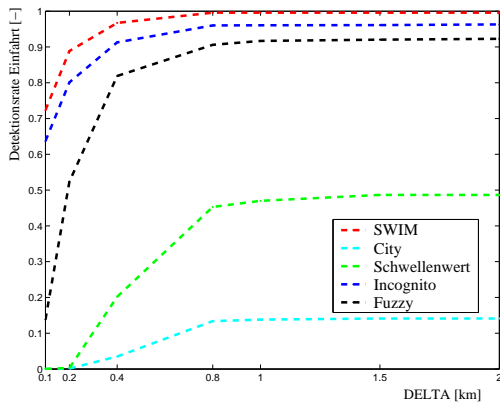
(a) Betrachtung der Einfahrt




(b) Betrachtung der Ausfahrt

Abbildung 7.11.: Detektionsrate versus Fehlalarmrate nach Stärkeklassen für $\lambda = 120s$ und $\delta = 2.0km$. Die Punkte markieren den Fall $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$, die Quadrate die Ergebnisse der verschiedenen Stärkeklassen.

Erzeugung neuer Informationen




(a) Betrachtung der Einfahrt




(b) Betrachtung der Ausfahrt

Abbildung 7.12.: Vergleich der Detektionsrate für Störungen der Stärkeklasse 1 für $\lambda = 300s$



(a) Betrachtung der Einfahrt für $\lambda = 300s$



(b) Betrachtung der Ausfahrt für $\lambda = 300s$

Abbildung 7.13.: Detektionsrate versus Fehlalarmrate nach Stärkeklassen für $\lambda = 300s$ und $\delta = 2.0km$

Bei Straßen ohne stationäre Detektoren wird eine robuste Erkennung gefordert. Die Abbildungen 7.12 und 7.13 stellen analog zu oben die Detektions- und Fehlalarmraten für eine erlaubte Meldeverzögerung von $\lambda = 300s$ dar. Die Qualität der Erkennung ist bei SWIM, Incognito und Fuzzy gleichwertig zu der bei $\lambda = 120s$. Dies bestätigt die schnelle Erkennung der Verfahren. Eine deutlich bessere Erkennung der Einfahrt insbesondere bei Störungen hoher Stärke ist jedoch bei City und Schwellenwert zu beobachten (siehe Abb. 7.12(a) und 7.13). Beide Verfahren reagieren stark auf die Dauer der Störung, während SWIM, Incognito und Fuzzy auf die Art des Geschwindigkeitsabfalls reagieren. City, und insbesondere Schwellenwert sind sehr robust. Durch die lange Plausibilisierung wurden beispielsweise von Schwellenwert ausschließlich solche Störungen detektiert, die auch durch das Referenzverfahren erfasst wurden.

7.2.5. Auflösungsvermögen der XFCD-Verfahren

Um ihr Auflösungsvermögen zu testen, werden die XFCD-Verfahren anhand von vier Szenarien mit aufeinander folgenden Störungen untersucht. Aufgrund der geringen Szenarienzahl können auf diese Weise nur unscharfe Aussagen getroffen werden. Die Untersuchung soll aber einen Eindruck über die Auflösung der Verfahren in diesen Fällen geben.

Bei der Analyse wird gefordert, dass die Verfahren die beiden Störungen getrennt erkennen. Diese Kenntnis führt, unabhängig von einer Weiterverarbeitung der Daten in einer Zentrale oder in nachfolgenden Fahrzeugen zu einem Mehrwert an Information und ist wichtig für die Lokale Gefahrenwarnung und die Verwendung vorausschauender Regler.

Abbildung 7.14 zeigt die Detektions- und Fehlalarmrate der vier Szenarien. Alle Verfahren weisen im Vergleich zu Einzelstörungen niedrigere Detektionsraten auf. Stärker betroffen sind die Verfahren Schwellenwert und Incognito, was eindeutig auf die fehlende Differenzierung zwischen den beiden Störungen zurückzuführen ist. Dagegen nimmt die Detektionsrate von City bei leicht erhöhter Fehlalarmrate zu. Dies kann mit der sehr schnellen Detektion der Ausfahrt erklärt werden.




Abbildung 7.14.: Detektionsrate versus Fehlalarmrate bei zwei aufeinander folgenden Störungen

Abbildung 7.15 zeigt als Beispiel die erkannten Störungen von SWIM für Szenario 16 (siehe Abschnitt 6.3.3). Die erste Störung wird durch eine Vollsperrung verursacht. Kurze Zeit später bleibt ein Zyklusfahrzeug erneut stehen. Auch hier zeigt SWIM wieder eine schnelle Detektion der Stauflanke bei der Einfahrt in die Störung. Die erkannten Stauflanken und Meldungen sind in rot bzw. blau markiert. Zum besseren Kontrast wird die Stauflanke der Ausfahrt in gelb dargestellt. Die schwarzen Punkte markieren die Ausfahrtsmeldung. Zu sehen ist hier die im Vergleich zur Einfahrt leicht verzögerte Detektion.




Abbildung 7.15.: Contourplot mit erkannten Störungen von SWIM

7.3. Plausibilitätsprüfung mit Realdaten

Die mit Realdaten durchgeführten Plausibilitätsprüfungen dienen zur Absicherung der in der Simulation erzielten Ergebnisse. Dazu wurde SWIM bereits während der Entwicklung immer wieder für durchgeführte XFCD-Versuchsfahrten überprüft.

7.3.1. Vergleich mit stationären Daten

Im Folgenden soll ein Beispiel für die Erkennung von SWIM bei realen Daten dargestellt werden. Die Daten stammen von einem im Juni 2002 durch die BMW AG durchgeführten Feldversuch.

Abbildung 7.16 zeigt die zwischen München-Freimann und AK Neufahrn aufgezeichneten Detektordaten für Freitag, den 28.06.2002. Die rot eingefärbten, kleinen Geschwindigkeiten im Bereich München-Nord zeigen einen während des gesamten Betrachtungsintervalls dort stattfindenden, ortsfesten Stau. Zusätzlich wandern zwei Stoßwellen von AK Neufahrn Richtung Freimann.

Im Rahmen des Feldtests fährt ein XFCD-Fahrzeug von München kommend gegen 14 : 52 in den Stau bei München Nord und verlässt diesen um 15 : 05. Um 15 : 10 erreicht es die zweite Stoßwelle. Die dazugehörige Geschwindigkeitsganglinie mit den erkannten Störungen und Versatzzeiten sind in Abbildung 7.17 dargestellt. Es zeigt sich, dass die Erkennung des ersten Staus schon frühzeitig erfolgt. Dies muss jedoch durch eine, im Vergleich zur zweiten Störung relativ langen Versatzzeit bestätigt werden. Dort findet ein steiler Geschwindigkeitsabfall statt. Die Ergebnisse der Erkennung zusammen mit der Geschwindigkeitstrajektorie sind den stationären Daten überlagert und zeigen mit ihnen eine gute Übereinstimmung (siehe Abb. 7.16). Das XFCD-Fahrzeug kann zu einem genaueren Bild über die Verkehrs-

situation beitragen und zwischen den Detektoren eine genauere Lokalisierung ermöglichen.




Abbildung 7.16.: XFCF Daten im Vergleich zu stationären Daten am Detektor




Abbildung 7.17.: Geschwindigkeitsganglinie

7.3.2. Fehlermanagement

Bei den simulierten Daten treten keine Datenfehler auf. Für die Überprüfung des Fehlermanagements in SWIM werden einige XFCD-Fahrten mit Datenfehlern analysiert. Dazu wird die Störungserkennung gemeinsam mit der Ausreißererkenung auf die Daten angewandt.




Abbildung 7.18.: Fehlermanagement in SWIM

Eine Beispielfahrt zeigt Abbildung 7.18. Es handelt sich dabei um keine Autobahnfahrt, sondern um eine Überlandfahrt zwischen der B2 bei Mammendorf und Klosterlechfeld in Bayern. Sie wird jedoch zur Veranschaulichung der Ausreißererkenung herangezogen. Wie erwünscht erkennt SWIM trotz teilweise stark wechselnder Geschwindigkeiten keine Verkehrsstörung. Darüber hinaus gelingt es SWIM die drei rot gekennzeichneten Ausreißer zu identifizieren und sie von einer Störung zu unterscheiden.

7.4. Zusammenfassung der Ergebnisse

Dieses Kapitel beschäftigte sich mit der Untersuchung des Verfahrens SWIM sowie dem Vergleich mit vier weiteren XFCD-Verfahren. Dazu wurde die Güte ihrer Störungserkennung untersucht und ihre Eignung speziell für die Anwendungsbereiche vorausschauende Regler, Lokale Gefahrenwarnung und routenwahlorientierten Verkehrsinformation geprüft. Dabei erfolgte die Analyse der XFCD-Verfahren für bestimmte zeitliche und örtliche Schwellenwerte. Die Ergebnisse wurden zusätzlich in Abhängigkeit der Störungsursachen und dem Stärkegrad der Störungen erfasst.

Es zeigt sich, dass *SWIM* die Forderungen einer zeitnahen und genauen Lokalisierung einer Störung sehr gut erfüllt. Eine Sensitivitätsanalyse mit drei weiteren Parametervarianten zeigte

die beste Qualität der Erkennung für die gewählten Parametervektoren und bestätigte die Ergebnisse der Optimierung. Die Meldung der Ausfahrt aus einer Störung erfolgt etwas verzögert, da sich diese über eine längere Strecke erstreckt. Insgesamt erzielt SWIM im Vergleich die höchste Detektionsrate für die untersuchten Szenarien.

Das *Verfahren City* zeigt im Vergleich zu den anderen Verfahren die niedrigste Erkennungsrate. Dabei muss jedoch berücksichtigt werden, dass es als einziges Verfahren nicht für Autobahnen ausgelegt wurde. Als innerstädtisches Verfahren reagiert es stark auf die Dauer kleiner Geschwindigkeiten. Durch eine Plausibilitätsprüfung von 200s erfolgt die zeitliche Meldung stark verzögert. Die Erkennung der Störungsausfahrt von City ist sehr empfindlich. So kann es vorkommen, dass aufgrund der Betrachtung der Beschleunigungswechsel eine Ausfahrt schon weit vor dem eigentlichen Störungsende erkannt wird. In der Regel erfolgt sie jedoch sehr zeitnah zur eigentlichen Ausfahrt. Dies führt mit der langen Überprüfdauer zu einer sehr geringen Fehlalarmrate.

Ebenfalls stark verzögert reagiert das *Verfahren Schwellenwert*. Nach Erkennung einer Störung muss eine Mindestverzögerung von 120s bis zur Meldung in Kauf genommen werden. Dies gilt auch bei der Ausfahrtsdetektion. Die sehr hohen Fehlalarmraten spiegeln das zeitlich verzögerte Meldungsmanagement, welches insbesondere bei der Ausfahrt zu erkennen ist, wider. Allerdings ist Schwellenwert aufgrund der langen Plausibilisierungszeit sehr robust und eignet sich sehr gut für die Erkennung in Gebieten, in denen keine weiteren Detektoren vorhanden sind.

Incognito zeigt die zweithöchste Detektionsrate für die Einfahrt. Durch die Betrachtung des normierten Beschleunigungsrauschens ist die Detektion sehr empfindlich, welches sich im Gegenzug auch auf die Fehlalarmraten niederschlägt. Die Betrachtung des Beschleunigungsrauschens führt dazu, dass auch streckenabhängige Topologien, die Schwankungen der Geschwindigkeit verursachen, stark in die Detektion eingehen. Die Erkennung der Ausfahrt erfolgt durch hart kodierte Warteparameter dagegen sehr verzögert.

Eine vergleichbare Güte zu SWIM erreicht das *Verfahren Fuzzy*. Es zeigt eine etwas niedrigere Fehlalarmrate bei gleichzeitig niedrigerer Detektionsrate für Einfahrt und Ausfahrt. Zu beachten ist die im Vergleich zu SWIM zeitlich, aber insbesondere örtlich versetzte Erkennung.

Anwendungen im Bereich vorausschauender Regler haben zum Ziel, den Verkehr in einem kleinräumigen Gebiet zu beeinflussen. Dies kann zum einen über eine Warnung nachfolgender Fahrer erfolgen, zum anderen über eine Regelung der Fahrzeuge untereinander. Informationen und Regelungen im kleinräumigen Netz erfordern allerdings eine örtlich sehr genaue Detektion. Aus diesem Grund wurden die Verfahren auf ihre Erkennung innerhalb einer örtlichen Genauigkeit von 100m bei der Einfahrt und 400m bei der Ausfahrt untersucht. SWIM zeigt für beide Bereiche die beste Erkennung. Keine Detektion in diesem Detaillierungsgrad ist mit

Schwellenwert sowie mit City für die Einfahrt und mit Incognito und Fuzzy für die Ausfahrt möglich.

Für die Lokale Gefahrenwarnung wurde nur die Einfahrt in eine Störung untersucht. Diese soll sehr zeitnah erfolgen, um nachfolgende Fahrer über eine Gefahrensituation zu warnen. Zu diesem Zweck wurde die Erkennung hinsichtlich einer zeitlichen Verzögerung von 90s untersucht. Hierbei zeigt SWIM das beste Ergebnis, gefolgt von Incognito und Fuzzy. Mit Schwellenwert und City ist eine zeitnahe Detektion nicht möglich.

Die Ergebnisse der XFCD-Verfahren wurden für diese beiden Anwendungen getrennt nach den Ursachen der Störungen untersucht. Dabei zeigt SWIM stets eine bessere Erkennungsgüte bei Sperrungen von 2-3 Spuren. Dieser Trend ist ebenfalls bei der Einfahrtserkennung von Incognito und Fuzzy zu beobachten. Dagegen weist City eine bessere Ausfahrtserkennung bei einzelnen Spersperrungen auf.

In einer Verkehrsinformationszentrale ist es wichtig, die Darstellung von Verfahren hinsichtlich ihrer Güte bei unterschiedlichem Schweregrad einzuschätzen. Es zeigte sich, dass bei der Einfahrt Störungen unterschiedlichen Störungsgrades gleichwertig, zum Teil jedoch leichtere Störungen besser erkannt wurden. Diese, auf den ersten Blick kontroverse, Ergebnisse in Bezug auf die Erkennung ergeben Sinn, wenn das Versuchsdesign in PELOPS mit berücksichtigt wird. So wurden aufgrund der beschränkten Strecke Sperrungen von zwei und drei Spuren nur 5 statt 15 Minuten durchgeführt. Dies führte dazu, dass die Einzelsperrungen den höchsten Schweregrad haben. Während die Verfahren SWIM, Fuzzy und Incognito auf die Stärke des Übergangs zwischen den Zuständen frei und gestaut reagieren, sind City und Schwellenwert stark von der Dauer einer Störung abhängig und erkennen Störungen hohen Schweregrades besser.

Bei der Einfahrt stellte sich heraus, dass die Stauausbreitung im Simulator bei Sperrung einzelner Spuren, speziell der linken Spur, nicht ganz realistisch verlief. So fuhren Fahrzeuge der Nachbarspuren zum Teil mit sehr hohen Geschwindigkeiten an der Störung vorbei und hatten keine Möglichkeit, die Störung zu erkennen. Dies hatte zudem eine Spurabhängigkeit des Ortes der Stoßwelle zur Folge. Die Verwendung einer Position als Repräsentant der Stauflanke über alle Spuren führte in diesem Fall zu ungenauen und zum Teil nicht gerechtfertigten örtlichen Fehlern. Bei Sperrungen von mehreren Spuren verlief die Stauausbreitung dagegen gleichmäßig. Dies führte zu einer teilweise höheren Detektionsrate bei Störungen geringer Stärke.

Bei der Ausfahrt hingegen wurden schwere Störungen in der Regel besser erfasst. Insbesondere bei größeren erlaubten zeitlichen Verzögerungen detektierten City und Schwellenwert jeweils Störungen hoher Stärke am besten.

8. Zusammenfassung und Ausblick

Diese Arbeit beschreibt die Entwicklung, die Optimierung und die Bewertung von SWIM - einem Verfahren zur Stoßwellenerkennung mittels Interventionsmodell. SWIM leistet eine zeitnahe und örtlich genaue Detektion und Lokalisierung von Verkehrsstörungen.

8.1. Zusammenfassung und Schlussfolgerungen

Neue Dienste im Fahrzeug wie beispielsweise routenwahlorientierte Verkehrsinformationen, Lokale Gefahrenwarnung oder die Auslegung vorausschauender Abstandsreglern stellen immer strengere Anforderungen an die Qualität der Störungserkennung. Diese werden von bisherigen Verfahren nur ungenügend erfüllt. So senden die aktuellen Erkennungsverfahren zeitlich verzögert und beschreiben den Ort des Geschehens nur ungenau.

Die bisher entwickelten Verfahren zur Erkennung von Verkehrsstörungen basieren hauptsächlich auf Daten stationärer Detektoren. Dabei kann eine Störung jedoch erst erkannt werden, wenn diese den Detektor erreicht. Eine Störungserkennung basierend auf stationären Daten birgt daher immer zeitliche Verzögerungen und örtliche Ungenauigkeiten. Aus diesem Grund stützt sich das neue Verfahren SWIM auf die Verwendung fahrzeuggenerierter Daten. Deren technische Nutzbarkeit wurde im Rahmen von Förderprojekten wie MOTIV oder INVENT weiterentwickelt. Aufgrund der hohen Kommunikationskosten für eine zentrale Datenauswertung soll die Erkennung mit SWIM im Fahrzeug stattfinden.

Bei der Betrachtung fahrzeuggenerierter Daten darf jedoch nicht vergessen werden, dass das einzelne Fahrzeug nur eine Stichprobe im Verkehrsablauf darstellt und sein Verhalten nicht immer dem der umgebenden Fahrzeuge bzw. dem Verkehrsstrom entspricht. Aus diesem Grund wurde für das Verfahren SWIM ein Ansatz gewählt, der neben dem Fahrtverlauf auch Rauschprozesse berücksichtigt.

SWIM ist modular aufgebaut. Es kann in zwei Funktionsbereiche unterteilt werden; dem des Fehlermanagements und dem Hauptbereich der Störungserkennung. Dieser wird weiter unterteilt in die Erkennung der Störungseinfahrt und der Störungsausfahrt. Für beide Bereiche bildet ein stochastisches Zeitreihenmodell den Kern der Erkennung. Dieses besteht in der Basis aus einem ARIMA-Modell für den freien Verkehr, welches um zwei Interventionsmodelle erweitert wurde.

Das ARIMA-Modell modelliert den Geschwindigkeitsverlauf eines Fahrzeugs im ungestörten Verkehr. Das Augenmerk wurde bei der Entwicklung auf die Form des ARIMA-Modells bei unterschiedlichen Fahrern und Fahrzeugen gelegt. Es stellte sich heraus, dass sowohl bei der Betrachtung unterschiedlicher Fahrer und einheitlichem Fahrzeug als auch bei variierten Fahrer-Fahrzeug-Einheiten die Modelle (1,1,1) und (1,1,2) die beste Darstellung liefern. Diese Ergebnisse werden auch bei unterschiedlichen Fahrzeugen und einheitlichem Fahrer bestätigt. Es kann also angenommen werden, dass, unabhängig von Fahrer und Fahrzeug, ein einheitliches ARIMA-Modell verwendet werden kann. Aufgrund der etwas besseren Ergebnisse wurde schließlich ein ARIMA-Modell (1,1,1) gewählt.

Nach der Modellierung des ungestörten Verkehrs wurde ein Modell für den gestörten Verkehr entwickelt. Dies erfolgt in SWIM mit Hilfe zweier Interventionsmodelle. Dazu wird überprüft, ob es Anhaltspunkte für die Wirkung einer Störung gibt. Das erste Modell untersucht Änderungen im Geschwindigkeitsniveau während das zweite Modell tiefe Geschwindigkeitsgefälle erkennt. Das zweite Modell wird auch zur Erkennung von Ausreißern, d.h. von fehlerhaften Daten, verwendet. Eine Störung wird zu diesem Zweck abstrakt als eine Sprung- bzw. Pulsfunktion modelliert und mit dem ARIMA-Modell überlagert. Ein Zeichen für eine Störung ist dann gegeben, wenn signifikante Abweichungen vom ungestörten Verlauf auftreten. Die Erkennung reagiert sehr stark auf die Änderung der Geschwindigkeitsniveaus. Je nach Parametereinstellung kann das Modell sehr empfindlich oder robust eingestellt werden. Zu diesem Zweck werden zusätzlich die Geschwindigkeitsdifferenzen und starke Verzögerungen betrachtet.

Die Festlegung der Parameter von SWIM erfolgte anhand einer Parametervariation. Aufgrund der hohen Dimension an zu optimierenden Parametern wurde ein genetischer Algorithmus gewählt. Dabei wurde die Qualität der Erkennung jeweils für drei Lernszenarien ermittelt. Von diesen enthielten zwei jeweils eine Störung, die dritte jedoch nur unruhigen Verkehr. Die Parameteroptimierung verfolgte dabei zwei gegensätzliche Ziele: die Maximierung der Erkennungsgüte bei gleichzeitiger Minimierung der Fehlalarmrate. Das Ergebnis der Optimierung zeigte jedoch keine eindeutige Konvergenz. Es ist zu vermuten, dass der Grund in den gegensätzlichen Zielkriterien lag. Aus diesem Grund wurden die Parametervektoren, die die höchste Güte bezüglich einer gemeinsamen Rate aus Detektions- und Fehlalarmrate aufwiesen, im Rahmen einer Clusteranalyse weiter untersucht.

Da eine repräsentative Datenbasis an realen Daten für die Bewertung von Erkennungsalgorithmen nicht zur Verfügung stand, und die vorhandenen stationären und fahrzeuggenerierten Realdaten keinen fein aufgelösten Vergleich zulassen, wurde ein simulationsbasierter Ansatz gewählt. Als Werkzeug wurde der submikroskopische Verkehrssimulator PELOPS gewählt. Da bisher kaum Massenszenarien in PELOPS gerechnet wurden, sollte diese Arbeit auch dessen Eignung für die Modellierung von Stausituationen feststellen.

Die Bewertung von SWIM erfolgte anhand einer Szenariendatenbank mit 104 simulierten Szenarien. Diese basieren auf realen Unfallpositionen. Für einen Teilabschnitt der A9 im Norden Münchens wurden 13 unterschiedliche Störungspositionen gewählt, und für jede 8 unterschiedliche Störungen verursacht. Dabei entstand bei sieben jeweils eine Störung, während die achte nur unruhigen Verkehr zeigt. Zusätzlich wurden noch vier Szenarien aufgebaut, die jeweils zwei aufeinander folgende Störungen zeigen. Zur Plausibilisierung wurde SWIM bereits während der Entwicklung an realen XFCD-Fahrten getestet.

Bisher existieren keine allgemein anerkannten Definitionen und Gütekriterien für die Bewertung von mikroskopischen Verfahren zur Störungserkennung. Aus diesem Grund wurden für die Anwendung geeignete Methoden entwickelt. Das Hauptkriterium der Bewertung stellt die Güte der Störungserkennung in Abhängigkeit der zeitlich verzögerten Meldung und des örtlichen Versatzes dar. Die Berechnung der Detektionsrate erfolgt dann anhand einer Auswahl an Schwellenwerten. Als weiteres Kriterium wurde eine Fehlalarmrate ermittelt.

Neben SWIM wurden vier weitere XFCD-Verfahren auf die Qualität ihrer Störungserkennung untersucht und speziell für die Anwendungsbereiche vorausschauende Regler, Lokale Gefahrenwarnung und Routenwahl bewertet. Dabei erfolgte die Analyse der XFCD-Verfahren für bestimmte zeitliche und örtliche Schwellenwerte. Die Ergebnisse wurden zusätzlich in Abhängigkeit der Störungsursachen und dem Stärkegrad der Störungen interpretiert. Zusammengefasst zeigt die Untersuchung deutlich, dass SWIM die Forderungen nach einer zeitnahen Erkennung mit geringem örtlichem Versatz sehr gut erfüllt. Es erzielte im Vergleich zu den anderen XFCD-Verfahren die höchste Detektionsrate. Weiter wurde gezeigt, dass SWIM, Incognito und Fuzzy stark auf die Stärke des Übergangs von Verkehrszuständen reagieren, während die Erkennung mit City und Schwellenwert auf der Dauer des niedrigen Geschwindigkeitsniveaus basiert. Durch die schlechte Detektion der Einfahrt ist eine Verwendung von City auf Autobahnen nicht zu empfehlen. Das Verfahren Schwellenwert ist ebenfalls nicht für zeit- und ortskritische Anwendungen geeignet. Durch seine Robustheit kann es jedoch sehr gut für die Generierung von Verkehrsinformationen in Gebieten ohne weitere Detektoren verwendet werden. Incognito ist sehr empfindlich bei der Erkennung von Einfahrten in eine Störung, kann aber Ausfahrten nur sehr verzögert erkennen. Diese ist dagegen bei Fuzzy sehr gut. Fuzzy eignet sich wie SWIM für zeit- und ortskritische Dienste, erkennt aber im Vergleich zu SWIM etwas zeitlich und örtlich versetzt. Sowohl bei der Einfahrt als auch bei der Ausfahrt wies SWIM bei allen sicherheitskritischen Anwendungen die besten Ergebnisse auf.

Das Verfahren SWIM wurde mit Hilfe von realen und simulierten Fahrzeugdaten entwickelt und programmtechnisch umgesetzt. Eine Evaluation auf der Basis einer umfassenden Szenariendatenbank an simulierten Störungen war erfolgreich. SWIM zeigt das Potential zur Erhöhung der Verkehrssicherheit und Effizienz des individuellen Fahrers sowie des Kollektivs. Aufgrund der Implementierung von SWIM auf C-Basis konnte das Verfahren bereits in ein Versuchsfahrzeug portiert werden.

8.2. Ausblick

Das Verfahren SWIM wurde für unterschiedliche Störungspositionen und Störungsursachen getestet. Nicht untersucht wurde hingegen eine Variation der Topologie wie etwa Autobahnauffahrten bzw. -abfahrten oder unterschiedliche Verkehrsstärken. Dies wäre notwendig, um ein umfassenderes Urteil über die Qualität der Verfahren abgeben zu können und müsste in einer Weiterführung der Arbeiten erfolgen. Die notwendigen Werkzeuge sind dafür bereitgestellt. Weiter ist es absolut notwendig, die Betrachtung auf Straßenkategorien wie Bundesstraßen oder Landstraßen zu erweitern. Restriktionen waren in dieser Arbeit, dass PELOPS mit der anfangs verfügbaren Version Bundesstraßen mit Spurverengungen nicht realistisch und unfallfrei nachbilden konnte. So war eine Bestimmung der Parameter für SWIM für diese Straßenkategorie nicht möglich. Durch die Adaption an das Verhalten der Fahrzeugtrajektorie erscheint es vielversprechend, den Algorithmus auch auf den Nicht-Autobahnverkehr zu erweitern. Dazu ist eine Neukalibrierung der Parameter erforderlich. Dies wird in dieser Arbeit nicht weiter verfolgt. Ebenso wenig wird in dieser Arbeit die Störungserkennung im Hinblick auf mögliche Wechsel der Straßenkategorie untersucht. Diese können mit der immer besser werdenden Qualität der digitalen Karten problemlos erkannt werden; eine algorithmische Abhandlung findet sich in HAUSCHILD (2003) und HUBER (2001). Dazu könnte eine Neukalibrierung von SWIM in Abhängigkeit der Straßenkategorie bzw. -klasse untersucht und das Verfahren je nach Kontext angepasst werden.

SWIM unterscheidet intern die Zustände frei, instabil und gestört. Bisher war das Ziel, Meldungen bezüglich der Zustände frei und gestört zu versenden. Durch eine Erweiterung des Meldemanagements wäre es möglich, die bisher noch sehr empfindliche Erkennung des Zustands instabil, auch zur Versendung von Informationen zu nutzen.

Eine Ausfahrt aus einem Stau erstreckt sich über ein weites Gebiet. SWIM betrachtet den Geschwindigkeitsanstieg und erkennt erst nach Beendigung des Übergangs den Zustand des freien Verkehrs. Der Erkennungszeitpunkt von SWIM könnte voraussichtlich weiter verbessert werden, indem die Kenntnis über den Geschwindigkeitsanstieg verarbeitet wird.

Wie oben besprochen wurde, hat sich gezeigt, dass die Annahme eines einheitlichen ARIMA-Modells für jeden Fahrer und jedes Fahrzeug gerechtfertigt ist. Es wäre jedoch möglich, dass die Verwendung individueller Eigenschaften wie Wunschgeschwindigkeit oder eine detailliertere Abbildung des Rucks, zu einer weiteren Verbesserung des Modells führen können.

Ein weiteres wichtiges Ziel ist die Erstellung von Prognosen über den weiteren Verlauf der Stoßwelle. Um diese zu verbessern, sollten neben typischen Stoßwellengeschwindigkeiten auch der Fahrtverlauf im Bereich der Stauflanke, insbesondere des Geschwindigkeitsgradienten, untersucht werden.

Bisherige Untersuchungen für mikroskopische Verfahren zur Erkennung von Verkehrsstörungen führten in der Regel einen Vergleich zu stationären Daten bzw. auf Basis makroskopischer

Gütekriterien durch. Für eine Bewertung mit einem Detaillierungsgrad, wie es für diese Arbeit gefordert wurde, musste somit erst ein Referenzverfahren entwickelt werden. Dieses basiert auf einem statistischen Signifikanztest, der zu jedem Simulationszeitpunkt die Geschwindigkeiten der Fahrzeuge im betrachteten Streckenabschnitt untersucht. Aufgrund der Einschränkung der Stoßwellenposition auf eine Position für alle Spuren ergeben sich jedoch Ungenauigkeiten bei ungleichmäßiger Stauausbreitung wie es bei Sperrungen der linken Spur im Simulator der Fall war. Diese wurde inzwischen im verwendeten Modell behoben. Für weiterführende Untersuchungen sollte das Referenzverfahren diesbezüglich jedoch erweitert werden. Insgesamt gesehen hat sich gezeigt, dass das entwickelte Referenzverfahren geeignet ist, die Stauflanke in einem zweidimensionalen Gebiet nachzubilden. Eine Nutzung bei Anwendungen wie beispielsweise der Kameraüberwachung wäre möglich.

In dieser Arbeit wurde die Qualität von XFCD-Verfahren bewertet. Ein einzelnes ausgestattetes Fahrzeug kann jedoch nicht die Qualität von Verkehrsinformationen verbessern. Die Qualität hängt neben einer zuverlässigen Meldung insbesondere auch davon ab, wie vollständig das Straßennetz abgedeckt werden kann und wie aktuell Verkehrsmeldungen erzeugt werden können. Dazu muss eine ausreichende Ausstattungsrate von XFCD-Fahrzeugen erreicht werden. Berechnungen der Ausstattungsrate können mit Hilfe von poissonverteilten Ankunftszeiten durchgeführt werden (siehe [HUBER 2001]). BREITENBERGER ET AL. (2004) berechneten, dass eine Ausstattungsrate von 4% genügen würde, um auf 80% des Autobahnnetzes aktuelle Verkehrsinformationen zu generieren. In diesem Zusammenhang ist auch von Interesse, wie gut eine Verkehrsstörung und ihr Verlauf makroskopisch mit Hilfe der Fusion von lokalisierten Störungen unterschiedlicher Fahrzeuge nachgebildet werden kann. Neben der Untersuchung von Methoden, wie etwa Interpolation oder Regression, sollte ein Schwerpunkt weiterführender Untersuchungen auf der Entwicklung von Prognosetechniken liegen. Auch die Ableitung von Aussagen über makroskopische Größen wie der Verkehrsdichte sollte dabei berücksichtigt werden.

Abbildungsverzeichnis

0.1. Allgemeine Struktur von SWIM	vii
0.2. Berechnung der Güte von Verfahren zur Erkennung von Verkehrsstörungen . .	viii
2.1. Navigationssystem mit BMW ASSIST	7
2.2. Meldekette am Beispiel BMW ASSIST	8
2.3. Verlauf der Qualität innerhalb der Meldekette (Quelle: [BOGENBERGER 2003])	9
2.4. Stationäre Erfassungssysteme	11
2.5. Datengrundlage für XFCD	13
3.1. Abstraktion des Verkehrsablaufs mit Hilfe von Deskriptoren	19
3.2. Darstellung mikroskopischer Geschwindigkeiten	20
3.3. Abhängigkeit des Fahrverlaufs vom Fahrer	22
3.4. Mikroskopische Betrachtung des Geschwindigkeitsverlaufs	23
3.5. Fahrzeugtrajektorien	25
3.6. Fahrzeugabstände	26
3.7. Verkehrsstärke-Dichte-Beziehungen	30
3.8. Verkehrsphasen in der Fluss-Dichte-Ebene [KERNER 2004]	32
3.9. Das Verfahren ASDA-FOTO (Quelle: [KERNER ET AL. 2003])	33
3.10. Verkehrsstärken am Engpass	34
3.11. Phasendiagramm [HELBING & TREIBER 2002]	34
3.12. Zustandsdiagramm des Verkehrs [KIM & KELLER 2001]	35
3.13. Kumulierte Fahrzeugankunftszeiten (Quelle: [BOGENBERGER ET AL. 2006A])	36
3.14. Definitionen von Verkehrsstörung nach einer Umfrage in den USA (Quelle: [BERTINI O.D.])	37
3.15. Steilster Gradient im Geschwindigkeitsverlauf	40
4.1. Unterteilung der Verfahren nach örtlichen Kriterien	42
4.2. Abweichung der Prognose vom tatsächlichen Fahrtverlauf bei makroskopischen Daten an einem Messquerschnitt	43
4.3. Stationäre Verkehrsdaten	45
4.4. Unterschied der Datenverarbeitung zwischen Baken- und Mobilfunkgestützten Verfahren	54
4.5. Geschwindigkeitsbereiche des Schwellenwertverfahrens	61

5.1. Zeitlich-räumliche Abtastung des Verkehrs	64
5.2. Allgemeine Struktur von SWIM	65
5.3. Modellierte Zustandsübergänge innerhalb von SWIM	66
5.4. Realisierung von Zufallsprozessen	67
5.5. Allgemeine Modellentwicklung eines ARIMA-Modells	70
5.6. Streckenverlauf der A92 vor dem Jahr 2003	71
5.7. Ergebnis der Parameterschätzung für Szenario 1	74
5.8. Vergleich der Prognosefehler der Modelle (1, 1, 1) und (1, 1, 2)	76
5.9. Modell der Geschwindigkeitszeitreihe bei Niveauänderung	78
5.10. Modellierung einer Störung mit Sprungfunktion	79
5.11. Modell der Geschwindigkeitszeitreihe bei Ausreißern	81
5.12. Struktur von SWIM	83
5.13. Erkennung der Störungseinfahrt von SWIM	84
5.14. Schwellenwerte bei der Einfahrt in die Störung	85
5.15. Erkennung der Ausfahrt aus der Störung	86
6.1. Berechnung der Güte von XFCD-Verfahren	89
6.2. Emulationsumgebung für die Entwicklung, die Optimierung und die Bewertung von XFCD-Verfahren	89
6.3. Darstellung des Versuchsaufbaus in zwei Ebenen	90
6.4. Wechselwirkungen zwischen den Hauptelementen des Verkehrs	91
6.5. Modularer Aufbau von PELOPS (Quelle: [HOCHSTÄDTER ET AL. 2000])	93
6.6. Streckenverlauf A9	95
6.7. Basisszenario: Szenario ohne erzeugte Störung	96
6.8. Ausgangssituation: Darstellung eines Staus mit durchfahrenden Fahrzeugtra- jektorien	99
6.9. Bestimmung der Detektionsrate in Abhängigkeit der zeitlichen Verzögerung λ und des örtlichen Versatzes δ	101
6.10. Darstellung des Gewinns an zusätzlich gewarnten Fahrzeugen bei sofortiger Er- kennung der Störung	102
6.11. Betrachtung der Streckenabschnitte für die Berechnung der Fehlalarmrate	104
6.12. Generierung von Geschwindigkeitsschnappschüssen für jeden Zeitschritt der Simulation	107
6.13. Identifikation von möglichen gestauten Bereichen: Die Kreuze geben die Ge- schwindigkeit der Fahrzeuge in Abhängigkeit von der Position auf einer zu- nächst beliebigen Spur an. Im abgebildeten Beispiel beginnt die Störung etwa bei Kilometer 1.7 und endet bei Kilometer 4.1.	108
6.14. Identifikation instabiler Bereiche: Diese sollen nicht als Stau erfasst werden.	111
6.15. Überlagerung des Referenzverfahrens auf einem Trajektorienplot	112

6.16. Erzeugte Daten bei der Simulation mit PELOPS	113
6.17. Bewertungsumgebung	114
6.18. Struktur des Genetischen Algorithmus	115
6.19. 2-Punkt-Rekombination	117
7.1. Detektionsrate von SWIM für die Erkennung der Einfahrt in eine Störung. Als Basis dient die gesamte Szenariendatenbank.	122
7.2. Detektionsrate von SWIM für die Erkennung der Ausfahrt aus einer Störung. Als Basis dient die gesamte Szenariendatenbank.	123
7.3. Detektionsrate Einfahrt versus Fehlalarmrate	125
7.4. Detektionsrate der Einfahrt der Verfahren City, Schwellenwert, Incognito und Fuzzy	130
7.5. Detektionsrate der Ausfahrt der Verfahren City, Schwellenwert, Incognito und Fuzzy	131
7.6. Detektionsrate der Einfahrt versus Fehlalarmrate	131
7.7. Vergleich der Detektionsrate für vorausschauende Regler	132
7.8. Detektionsrate versus Fehlalarmrate für vorausschauende Regler. Die Punkte markieren den Fall $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$, die Quadrate den Fall $\lambda = 300s$ und $\delta = 100m$ bzw. $\delta = 400m$	133
7.9. Detektions- und Fehlalarmraten für die Lokale Gefahrenwarnung bei Betrachtung der Einfahrt für $\lambda = 90s$. Abbildung 7.9(b) zeigt den Vergleich zwischen den Fällen $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$ (Punkte) und $\delta = 2.0km$ und $\lambda = 90s$ (Quadrate).	134
7.10. Vergleich der Detektionsrate für Störungen der Stärkeklasse 1 für $\lambda = 120s$	135
7.11. Detektionsrate versus Fehlalarmrate nach Stärkeklassen für $\lambda = 120s$ und $\delta = 2.0km$. Die Punkte markieren den Fall $\delta \rightarrow \infty$ und $\lambda \rightarrow \infty$, die Quadrate die Ergebnisse der verschiedenen Stärkeklassen.	135
7.12. Vergleich der Detektionsrate für Störungen der Stärkeklasse 1 für $\lambda = 300s$	136
7.13. Detektionsrate versus Fehlalarmrate nach Stärkeklassen für $\lambda = 300s$ und $\delta = 2.0km$	136
7.14. Detektionsrate versus Fehlalarmrate bei zwei aufeinander folgenden Störungen	137
7.15. Contourplot mit erkannten Störungen von SWIM	138
7.16. XFCD Daten im Vergleich zu stationären Daten am Detektor	139
7.17. Geschwindigkeitsganglinie	139
7.18. Fehlermanagement in SWIM	140
C.1. Vergleich der Detektionsrate für die Erkennung der Einfahrt nach Stärke der Störung für $\lambda = 120s$ in Abhängigkeit von δ	166
C.2. Vergleich der Detektionsrate für die Erkennung der Einfahrt nach Stärke der Störung für $\lambda = 300s$ in Abhängigkeit von δ	167

C.3. Vergleich der Detektionsrate für die Erkennung der Ausfahrt nach Stärke der Störung für $\lambda = 120\text{s}$	169
C.4. Vergleich der Detektionsrate für die Erkennung der Ausfahrt nach Stärke der Störung für $\lambda = 300\text{s}$ in Abhängigkeit von δ	169

Tabellenverzeichnis

2.1. Methoden der fahrzeuggenerierten Erfassung	12
3.1. Mikroskopische Einteilung der Verkehrsqualitäten [BREITENBERGER 1997]	24
3.2. Stufen der Verkehrsqualität [FGSV 2001]	28
4.4. XFCD-Verfahren	56
5.1. Entwicklungsszenarien für das ARIMA-Modell des ungestörten Verkehrs	72
5.2. Modellvorschläge für das ARIMA-Modell nach der Modellidentifikation	73
5.3. Maximale Parameterdifferenz bei unterschiedlichen Fahrern und einheitlichem Fahrzeug	75
5.4. Mittelwerte der Parameter nach der Parameterschätzung	76
5.5. Standardabweichung der Parameter	77
5.6. Zu optimierende Parameter von SWIM	87
6.1. Messquerschnitte innerhalb des Untersuchungsgebiets	95
6.2. Positionen der Störungen im Szenario	97
6.3. Modellierte Störungsursachen	98
6.4. Szenarien zur Erzeugung von aufeinander folgenden Störungen	98
6.5. Ergebnis der Parametervariation für die Staueinfahrt	109
6.6. Ergebnis der Parametervariation für die Stauausfahrt	110
6.7. Randbedingungen des Genetischen Algorithmus	118
6.8. Parameter der einzelnen Module von SWIM	119
7.1. Parametersätze für die Varianten L1, L2 und Z1	120
7.2. Schwellenwerte λ und δ für die Untersuchung unterschiedlicher Anwendungsbereiche	125
7.3. Einteilung der Stärkeklassen in Abhängigkeit von der Ursache, der Dauer und der Position der Störung (siehe Tabellen 6.2 und 6.3 der Untersuchungsmethodik)	128
7.4. Detektionsrate Einfahrt von SWIM PA für die Klassen 1,2 und 3 und $\lambda = 120s$	128
7.5. Detektionsrate Ausfahrt von SWIM PA für die Stärkeklassen 1,2 und 3 und $\lambda = 120s$	129
C.1. Detektionsraten der Einfahrt von SWIM, City, Schwellenwert, Incognito und Fuzzy für $\delta = 0.1km$ in Abhängigkeit von λ	162

C.2. Detektionsraten der Ausfahrt von SWIM, City, Schwellenwert, Incognito und Fuzzy für $\delta = 0.4\text{km}$ in Abhängigkeit von λ	164
C.3. Detektionsraten der Einfahrt von SWIM, City, Schwellenwert, Incognito und Fuzzy für $\lambda = 90\text{s}$ in Abhängigkeit von δ	166
C.4. Detektionsraten der Einfahrt von SWIM für $\lambda = 120\text{s}$ in Abhängigkeit von δ nach Reisezeitverlust	167
C.5. Detektionsraten der Einfahrt von SWIM für $\lambda = 300\text{s}$ in Abhängigkeit von δ nach Reisezeitverlust	167
C.6. Detektionsraten der Ausfahrt von SWIM für $\lambda = 120\text{s}$ in Abhängigkeit von δ nach Reisezeitverlust	168
C.7. Detektionsraten der Ausfahrt von SWIM für $\lambda = 300\text{s}$ in Abhängigkeit von δ nach Reisezeitverlust	168
D.1. Parameter der XFCD-Verfahren Fuzzy, Incognito, City und Schwellenwert . . .	170
D.2. Konstante Versuchsvariable	171

A. Abkürzungsverzeichnis

Akronyme

ADAC	Allgemeiner Deutscher Automobilclub
ACC	Adaptive Cruise Control (deutsch: Abstandsregeltempomat)
AID	Automatic incident detection (deutsch: Automatische Störungserkennung)
ARIMA	Autoregressiver integrierter moving-average Prozess
ASDA	Automatische Staudynamikanalyse
AZTEK	Automatische zeitlich-räumliche Störungserkennung
DDG	Deutsche Gesellschaft für Verkehrsdaten mbH
ESE	Erweiterte Situationserkennung
FC	Floating Car
FCD	Floating Car Data
FGSV	Forschungsgesellschaft für Straßen- und Verkehrswesen eV
FOTO	Forecasting of Traffic Objects
GATS	Global Automotive Telematics Standard
GEZ	Gebühreneinzugszentrale
GDV	Gesamtverband der Deutschen Versicherungswirtschaft e.V.
GPS	Global Positioning System
GPRS	General Packet Radio Service
GSM	Global System for Mobile Communication
HBS	Handbuch zur Bemessung von Straßenverkehrsanlagen
INCOGNITO	In Car Originated Information for Telematic Operation
LGW	Lokale Gefahrenwarnung
LMS	Landesmeldestelle
MOSAR	Mobile Sensor Auto-Reporting Algorithm
MOSES	Mobile Sensor and Sample-Based Algorithm
ÖPNV	Öffentliche Personennahverkehr
PELOPS	Programmsystem zur Entwicklung Längsdynamischer mikroskopischer Verkehrsprozesse in Systemrelevanter Umgebung

PDA	Personal Digital Assistent
RDS-TMC	Radio Daten System - Traffic Message Channel (Digitaler Verkehrsfunkkanal)
SBA	Streckenbeeinflussungsanlage
SES	Stationäres Erfassungssystem
SMS	Short Message Service
SPIDER	Software Programming Interface for Distributed Realtime Driving Simulation
SSI	Standard Sensor Interface
SWIM	Stoßwellen Erkennung mittels Interventionsmodell
TLS	Technische Lieferbedingungen für Streckenstationen
UKW	Ultrakurzwelle
VISSIM	Verkehr in Städten - Simulation
VRZ	Verkehrsrechnerzentrale
XFACE	Exchange Interface (PELOPS-Schnittstelle)
XFCD	Extended Floating Car Data

Projekte

DVB	Dynamisches Verkehrsleitsystem Berlin
INVENT	Intelligenter Verkehr und nutzergerechte Technik
LISB	Leit- und Informationssystem Berlin
LoCoMoTiV	Localisation and Communication in MoTiV
MOTIV	Mobilität und Transport im intermodalen Verkehr
PROMETHEUS	Programme for a European Traffic with Highest Efficiency and Unprecedented Safety
RHAPIT	Rhein-Main-Area Project for Integrated Traffic Management
STORM	Stuttgart Transport Operation by Regional Management
VERDI	Vehicle Related Dynamic Information
VLA	Verkehrsleistungsassistentz

B. Symbolverzeichnis

Lateinische Symbole

a	$[\frac{m}{s^2}]$	Beschleunigung
\bar{a}	$[\frac{m}{s^2}]$	Mittlere Beschleunigung
a_t	$[-]$	Zeitreihe des weißen Rauschens
B	$[-]$	Rückhalteoperator
c	$[\frac{km}{h}]$	Ausbreitungsgeschwindigkeit der kinematischen Wellen
d	$[-]$	Ordnung des integrierenden Operators des ARIMA-Modells
DR_{Ein}	$[-]$	Detektionsrate der Einfahrt
DR_{Aus}	$[-]$	Detektionsrate der Ausfahrt
DR_{Gesamt}	$[-]$	Detektionsrate eines Szenarios
F	$[-]$	Optimum bei der genetischen Optimierung bzw. Quantil der t-Verteilung
$F(r)$	$[-]$	Fitnessfunktion bei der genetischen Optimierung
FR	$[-]$	Fehlalarmrate
FR_{Gesamt}	$[-]$	Fehlalarmrate eines Szenarios
J	$[\frac{km}{h}]$	Geschwindigkeit der stromabwärtigen Staufront eines breiten, sich bewegenden Stau
k	$[\frac{Fzge}{km}]$	Verkehrsdichte
k_{max}	$[\frac{Fzge}{km}]$	Verkehrsdichte an der Kapazität
k_{max}^{frei}	$[\frac{Fzge}{km}]$	Maximale Verkehrsdichte im freien Verkehr
$k_{max}^{gestaut}$	$[\frac{Fzge}{km}]$	Maximale Verkehrsdichte im gestauten Verkehr
k_{min}	$[\frac{Fzge}{km}]$	Verkehrsdichte im freien Verkehr, die im Ausfluss eines breiten, sich bewegenden Staus entsteht
$L_{Strecke}$	$[m]$	Streckenabschnitt

m	$[-]$	Anzahl der Beobachtungen der Zeitreihe N_t
n	$[-]$	Anzahl allgemein
n	$[-]$	Anzahl der Beobachtungen der differenzierten Zeitreihe z_t
$n_{E,Aus}$	$[-]$	Anzahl erkannter Flanken bei der Ausfahrt
$n_{E,Ein}$	$[-]$	Anzahl erkannter Flanken bei der Einfahrt
$n_{F,Aus}$	$[-]$	Anzahl durchfahrener Flanken bei der Ausfahrt
$n_{F,Ein}$	$[-]$	Anzahl durchfahrener Flanken bei der Einfahrt
$n_{Fzg,Aus}$	$[-]$	Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R bei Ausfahrt aus der Störung
$n_{Fzg,Ein}$	$[-]$	Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R bei Einfahrt in die Störung
$n_{Fzg,M,Aus}$	$[-]$	Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R und außerhalb der Störung bei Meldung der Ausfahrt
$n_{Fzg,M,Ein}$	$[-]$	Anzahl nachfolgender Fahrzeuge innerhalb der Reichweite R und außerhalb der Störung bei Meldung der Einfahrt
$N(x,t)$	$[-]$	Kumulative Anzahl an Fahrzeugen an einem Ort x zu einem Zeitpunkt t
N_t	$[-]$	Zeitreihe
p	$[-]$	Ordnung des autoregressiven Operators $\phi(B)$ des ARIMA-Modells
$P_t^{(T)}$	$[-]$	Pulsfunktion zum Zeitpunkt T
PR	$[-]$	Prävalenz
q	$[-]$	Ordnung des moving average Operators $\theta(B)$ des ARIMA-Modells
q	$[\frac{Fzge}{h}]$	Verkehrsstärke
q_{aus}	$[\frac{Fzge}{h}]$	Verkehrsstärke im Ausfluss aus dem Stau bzw. laut KERNER (2004): Verkehrsstärke im freien Verkehr, der im Ausfluss eines breiten, sich bewegenden Staus entsteht
q_{in}	$[\frac{Fzge}{h}]$	Verkehrsstärke auf der Hauptfahrbahn
q_{max}	$[\frac{Fzge}{h}]$	Maximale Verkehrsstärke
q_{max}^{frei}	$[\frac{Fzge}{h}]$	Maximale Verkehrsstärke im freien Verkehr

q_{Rampe}	$[\frac{Fzge}{h}]$	Verkehrsstärke der Rampe
r	$[-]$	Individuum bei der genetischen Optimierung
R	$[m]$	Kommunikationsreichweite
Rn	$[\frac{1}{s}]$	Normiertes Beschleunigungsrauschen
$S(\omega, \phi, \theta)$	$[-]$	Funktion der Fehlerquadratsumme
$S_t^{(T)}$	$[-]$	Sprungfunktion zum Zeitpunkt T
s	$[-]$	Schätzung der Streuung
t	$[s]$	Zeit
t_{Aus}	$[s]$	Zeitpunkt der Störungsausfahrt
$t_{E,Aus}$	$[s]$	Zeitpunkt der Erkennung einer Störungsausfahrt
$t_{E,Ein}$	$[s]$	Zeitpunkt der Erkennung einer Störungseinfahrt
t_{Ein}	$[s]$	Zeitpunkt der Störungseinfahrt
Δt_b	$[s]$	Bruttozeitlücke
$t_{M,Aus}$	$[s]$	Zeitpunkt der Meldung einer Störungsausfahrt
$t_{M,Ein}$	$[s]$	Zeitpunkt der Meldung einer Störungseinfahrt
Δt_n	$[s]$	Nettozeitlücke
$t_{Simulation}$	$[s]$	Endzeit einer Simulation
t_{ttc}	$[s]$	Auffahrzeit
T	$[s]$	Zeitintervall oder bestimmter Zeitpunkt
T_M	$[s]$	Zeitdauer, für die eine Störung gemeldet wird
T_E	$[s]$	Zeitdauer, in der eine Störung durchfahren wird und die als Störung erkannt wird
T_{RZ}	$[s]$	Reisezeit
$T_{RZBasis}$	$[s]$	Gesamtreisezeit aller Fahrzeuge in einem störungsfreiem Basisszenario
$T_{RZgesamt}$	$[s]$	Gesamtreisezeit aller Fahrzeuge eines Szenarios
$T_{RZverlust}$	$[s]$	Durchschnittlicher Reisezeitverlust
u	$[\frac{km}{h}]$	Geschwindigkeit der Stoßwelle
v	$[\frac{m}{s}]$	Geschwindigkeit

v_f	$\left[\frac{m}{s}\right]$	Wunschgeschwindigkeit
\bar{v}	$\left[\frac{m}{s}\right]$	Mittlere Geschwindigkeit
v_{grenz}	$\left[\frac{m}{s}\right]$	Geschwindigkeitsschwellenwert Referenzverfahren
v_m	$\left[\frac{m}{s}\right]$	Momentane Geschwindigkeit
v_{min}^{frei}	$\left[\frac{m}{s}\right]$	Minimal mögliche Geschwindigkeit im freien Verkehr
v_R	$\left[\frac{m}{s}\right]$	Reisegeschwindigkeit
v_x	$\left[\frac{m}{s}\right]$	Streckengeschwindigkeit
v_t	$\left[\frac{m}{s}\right]$	Geschwindigkeit zum Zeitpunkt t
x	$[m]$	Position
x_{Aus}	$[m]$	Position des Fahrzeugs bei Ausfahrt aus der Störung
Δx_b	$[m]$	Bruttoabstand zweier Fahrzeuge
$x_{E,Aus}$	$[m]$	Position des Fahrzeugs bei Erkennung einer Störungsausfahrt
$x_{E,Ein}$	$[m]$	Position des Fahrzeugs bei Erkennung einer Störungseinfahrt
x_{Ein}	$[m]$	Position des Fahrzeugs bei Einfahrt in die Störung
$x_{F,Aus}$	$[m]$	Position der Stauflanke zum Zeitpunkt der Meldung der Störungsausfahrt
$x_{F,Ein}$	$[m]$	Position der Stauflanke zum Zeitpunkt der Meldung der Störungseinfahrt
$x_{M,Aus}$	$[m]$	Position des Fahrzeugs bei Meldung einer Störungsausfahrt
$x_{M,Ein}$	$[m]$	Position des Fahrzeugs bei Meldung einer Störungseinfahrt
Δx_n	$[m]$	Nettoabstand zweier Fahrzeuge
\mathcal{Y}_t	$[-]$	Zeitreihe der Wirkung eines externen Ereignisses
Y_t	$[-]$	Reale Geschwindigkeitszeitreihe
z_t	$[-]$	Von N_t differenzierte Zeitreihe

Griechische Symbole

α	$[-]$	Signifikanzniveau
----------	-------	-------------------

δ	[–]	Schwellenwert des örtlichen Versatzes für die Störungserkennung
$\phi(B)$	[–]	Autoregressive Operator eines ARIMA-Modells
ϕ_1, \dots, ϕ_p	[–]	Parameter des autoregressiven Prozesses
$\varphi(B)$	[–]	Autoregressive integrierende Operator eines ARIMA-Modells
λ	[–]	Schwellenwert der zeitlichen Verzögerung für die Störungserkennung bzw. statistische Testgröße
μ	[–]	Mittelwert
$\theta(B)$	[–]	Moving Average Operator eines ARIMA-Modells
$\theta_1, \dots, \theta_q$	[–]	Parameter des moving-average Prozesses
σ	[–]	Standardabweichung
σ_a	[–]	Standardabweichung des weißen Rauschens
σ_B	$[\frac{m}{s^2}]$	Beschleunigungsrauschen
τ_{Aus}	[–]	Warnrate bei der Ausfahrt aus einer Störung
τ_{Ein}	[–]	Warnrate bei der Einfahrt in eine Störung
ω_1	[–]	Parameter des Niveauänderungsmodells
ω_2	[–]	Parameter des Ausreißermodells
$\hat{\omega}$	[–]	Schätzung für ω

Sperrung mittlere und rechte Spur	0.456	0.456	0.456	0.456	0.456	0.456	0.456
Sperrung linke und mittlere Spur	0.463	0.463	0.463	0.463	0.463	0.463	0.463
Sperrung linke und rechte Spur	0.392	0.395	0.395	0.395	0.395	0.395	0.395
City							
Sperrung rechte Spur	0	0	0	0	0	0.002	0.002
Sperrung mittlere Spur	0	0	0	0	0	0	0
Sperrung linke Spur	0	0	0	0	0	0	0
Vollsperrung	0	0	0	0	0	0	0
Sperrung mittlere und rechte Spur	0	0	0	0	0	0	0
Sperrung linke und mittlere Spur	0	0	0	0	0	0	0
Sperrung linke und rechte Spur	0	0	0	0	0	0	0
Schwellenwert							
Sperrung rechte Spur	0	0	0.003	0.004	0.007	0.007	0.007
Sperrung mittlere Spur	0	0	0	0	0	0	0
Sperrung linke Spur	0	0	0	0	0	0	0
Vollsperrung	0	0	0.004	0.004	0.004	0.004	0.004
Sperrung mittlere und rechte Spur	0	0	0	0	0	0	0
Sperrung linke und mittlere Spur	0	0	0	0	0	0	0
Sperrung linke und rechte Spur	0	0	0	0	0	0	0
Incognito							
Sperrung rechte Spur	0.511	0.511	0.511	0.511	0.511	0.511	0.511
Sperrung mittlere Spur	0.512	0.512	0.512	0.512	0.512	0.512	0.512
Sperrung linke Spur	0.442	0.442	0.442	0.442	0.442	0.442	0.442
Vollsperrung	0.606	0.606	0.606	0.606	0.606	0.606	0.606
Sperrung mittlere und rechte Spur	0.668	0.668	0.668	0.668	0.668	0.668	0.668
Sperrung linke und mittlere Spur	0.619	0.619	0.619	0.619	0.619	0.619	0.619
Sperrung linke und rechte Spur	0.612	0.612	0.612	0.612	0.612	0.612	0.612
Fuzzy							
Sperrung rechte Spur	0.061	0.074	0.074	0.074	0.074	0.074	0.074
Sperrung mittlere Spur	0.069	0.097	0.097	0.097	0.097	0.097	0.097
Sperrung linke Spur	0.041	0.068	0.068	0.068	0.068	0.068	0.068
Vollsperrung	0.096	0.124	0.124	0.124	0.124	0.124	0.124
Sperrung mittlere und rechte Spur	0.119	0.154	0.154	0.154	0.154	0.154	0.154
Sperrung linke und mittlere Spur	0.115	0.147	0.147	0.147	0.147	0.147	0.147
Sperrung linke und rechte Spur	0.090	0.111	0.111	0.111	0.111	0.111	0.111

Tabelle C.1.: Detektionsraten der Einfahrt von SWIM, City, Schwellenwert, Incognito und Fuzzy für $\delta = 0.1\text{km}$ in Abhängigkeit von λ

Sperrung	λ						
	60s	90s	120s	150s	180s	240s	300s
SWIM PA							
Gesamtbetrachtung	0.489	0.494	0.494	0.494	0.494	0.494	0.494
Sperrung rechte Spur	0.419	0.424	0.424	0.426	0.426	0.426	0.426

Sperrung mittlere Spur	0.491	0.503	0.504	0.504	0.504	0.504	0.504
Sperrung linke Spur	0.407	0.408	0.409	0.409	0.409	0.409	0.409
Vollsperrung	0.561	0.561	0.561	0.561	0.561	0.561	0.561
Sperrung mittlere und rechte Spur	0.572	0.578	0.578	0.578	0.578	0.578	0.578
Sperrung linke und mittlere Spur	0.556	0.559	0.559	0.559	0.559	0.559	0.559
Sperrung linke und rechte Spur	0.54	0.54	0.54	0.540	0.540	0.540	0.540
SWIM L1							
Gesamtbetrachtung	0.492	0.496	0.497	0.497	0.497	0.497	0.497
Sperrung rechte Spur	0.418	0.424	0.424	0.426	0.426	0.426	0.426
Sperrung mittlere Spur	0.489	0.501	0.502	0.502	0.502	0.502	0.502
Sperrung linke Spur	0.407	0.408	0.409	0.409	0.409	0.409	0.409
Vollsperrung	0.575	0.575	0.575	0.575	0.575	0.575	0.575
Sperrung mittlere und rechte Spur	0.572	0.578	0.578	0.578	0.578	0.578	0.578
Sperrung linke und mittlere Spur	0.556	0.559	0.559	0.559	0.559	0.559	0.559
Sperrung linke und rechte Spur	0.5384	0.538	0.538	0.539	0.539	0.539	0.539
SWIM L2							
Gesamtbetrachtung	0.491	0.496	0.496	0.497	0.497	0.497	0.497
Sperrung rechte Spur	0.416	0.421	0.421	0.423	0.423	0.423	0.423
Sperrung mittlere Spur	0.4888	0.501	0.502	0.502	0.502	0.502	0.502
Sperrung linke Spur	0.407	0.408	0.409	0.409	0.409	0.409	0.409
Vollsperrung	0.575	0.575	0.575	0.575	0.575	0.575	0.575
Sperrung mittlere und rechte Spur	0.572	0.578	0.578	0.578	0.578	0.578	0.578
Sperrung linke und mittlere Spur	0.556	0.559	0.559	0.559	0.559	0.559	0.559
Sperrung linke und rechte Spur	0.539	0.539	0.539	0.54	0.54	0.54	0.54
SWIM Z1							
Gesamtbetrachtung	0.492	0.497	0.497	0.498	0.498	0.498	0.498
Sperrung rechte Spur	0.416	0.422	0.422	0.423	0.423	0.423	0.423
Sperrung mittlere Spur	0.49	0.502	0.503	0.503	0.503	0.503	0.503
Sperrung linke Spur	0.408	0.410	0.411	0.411	0.411	0.411	0.411
Vollsperrung	0.576	0.576	0.576	0.576	0.576	0.576	0.576
Sperrung mittlere und rechte Spur	0.571	0.576	0.576	0.576	0.576	0.576	0.576
Sperrung linke und mittlere Spur	0.556	0.559	0.559	0.559	0.559	0.559	0.559
Sperrung linke und rechte Spur	0.54	0.54	0.54	0.54	0.54	0.54	0.54
City							
Sperrung rechte Spur	0.47	0.470	0.471	0.471	0.471	0.471	0.471
Sperrung mittlere Spur	0.525	0.525	0.525	0.525	0.525	0.525	0.525
Sperrung linke Spur	0.685	0.686	0.688	0.688	0.688	0.688	0.688
Vollsperrung	0.2888	0.289	0.289	0.289	0.289	0.289	0.289
Sperrung mittlere und rechte Spur	0.144	0.144	0.144	0.144	0.144	0.144	0.144
Sperrung linke und mittlere Spur	0.16	0.16	0.16	0.16	0.16	0.16	0.16
Sperrung linke und rechte Spur	0.136	0.136	0.137	0.137	0.137	0.137	0.137
Schwellenwert							
Sperrung rechte Spur	0	0	0	0	0	0	0
Sperrung mittlere Spur	0	0	0	0	0	0	0

Sperrung linke Spur	0	0	0	0	0	0	0
Vollsperrung	0	0	0	0	0	0	0
Sperrung mittlere und rechte Spur	0	0	0	0	0	0	0
Sperrung linke und mittlere Spur	0	0	0	0	0	0	0
Sperrung linke und rechte Spur	0	0	0	0	0	0	0
Incognito							
Sperrung rechte Spur	0.02	0.02	0.02	0.02	0.02	0.02	0.02
Sperrung mittlere Spur	0.034	0.034	0.034	0.034	0.034	0.034	0.034
Sperrung linke Spur	0	0	0	0	0	0	0
Vollsperrung	0	0	0	0	0	0	0
Sperrung mittlere und rechte Spur	0	0	0	0	0	0	0
Sperrung linke und mittlere Spur	0	0	0	0	0	0	0
Sperrung linke und rechte Spur	0	0	0	0	0	0	0
Fuzzy							
Sperrung rechte Spur	0.009	0.009	0.009	0.009	0.009	0.009	0.009
Sperrung mittlere Spur	0.006	0.006	0.006	0.006	0.006	0.006	0.006
Sperrung linke Spur	0.005	0.005	0.005	0.005	0.005	0.005	0.005
Vollsperrung	0	0	0	0	0	0	0
Sperrung mittlere und rechte Spur	0.014	0.014	0.014	0.014	0.014	0.014	0.014
Sperrung linke und mittlere Spur	0.003	0.003	0.003	0.003	0.003	0.003	0.003
Sperrung linke und rechte Spur	0.0059	0.006	0.006	0.006	0.006	0.006	0.006

Tabelle C.2.: Detektionsraten der Ausfahrt von SWIM, City, Schwellenwert, Incognito und Fuzzy für $\delta = 0.4\text{km}$ in Abhängigkeit von λ

Anwendungen im Bereich der Lokalen Gefahrenwarnung

Sperrung	δ						
	0.1km	0.2km	0.4km	0.8km	1.0km	1.5km	2.0km
SWIM PA							
Gesamtbetrachtung	0.629	0.814	0.931	0.960	0.960	0.961	0.961
Sperrung rechte Spur	0.591	0.759	0.885	0.91	0.911	0.911	0.911
Sperrung mittlere Spur	0.625	0.817	0.925	0.944	0.944	0.944	0.944
Sperrung linke Spur	0.498	0.699	0.887	0.947	0.947	0.948	0.948
Vollsperrung	0.672	0.879	0.982	0.994	0.994	0.994	0.994
Sperrung mittlere und rechte Spur	0.789	0.933	0.982	0.997	0.997	0.997	0.997
Sperrung linke und mittlere Spur	0.759	0.924	0.981	1.00	1.00	1.00	1.00
Sperrung linke und rechte Spur	0.648	0.836	0.952	0.999	0.999	0.999	0.999
SWIM L1							
Gesamtbetrachtung	0.595	0.794	0.925	0.959	0.959	0.959	0.959
Sperrung rechte Spur	0.551	0.737	0.876	0.908	0.909	0.909	0.909
Sperrung mittlere Spur	0.584	0.795	0.917	0.941	0.941	0.941	0.941
Sperrung linke Spur	0.468	0.670	0.878	0.947	0.947	0.947	0.947

Vollsperrung	0.634	0.863	0.980	0.991	0.991	0.991	0.991
Sperrung mittlere und rechte Spur	0.782	0.923	0.975	0.993	0.993	0.993	0.993
Sperrung linke und mittlere Spur	0.727	0.91	0.976	0.999	0.999	0.999	0.999
Sperrung linke und rechte Spur	0.616	0.817	0.942	0.998	0.998	0.998	0.998
SWIM L2							
Gesamtbetrachtung	0.605	0.798	0.925	0.959	0.959	0.959	0.959
Sperrung rechte Spur	0.562	0.742	0.875	0.906	0.907	0.907	0.907
Sperrung mittlere Spur	0.597	0.799	0.917	0.941	0.941	0.941	0.941
Sperrung linke Spur	0.473	0.676	0.879	0.947	0.947	0.947	0.947
Vollsperrung	0.645	0.865	0.98	0.992	0.992	0.992	0.992
Sperrung mittlere und rechte Spur	0.786	0.923	0.975	0.993	0.993	0.993	0.9925
Sperrung linke und mittlere Spur	0.74	0.913	0.978	1.00	1.00	1.00	1.00
Sperrung linke und rechte Spur	0.624	0.821	0.943	0.999	0.999	0.999	0.999
SWIM Z1							
Gesamtbetrachtung	0.412	0.562	0.723	0.959	0.959	0.959	0.959
Sperrung rechte Spur	0.409	0.555	0.712	0.904	0.907	0.908	0.908
Sperrung mittlere Spur	0.415	0.573	0.728	0.941	0.941	0.941	0.941
Sperrung linke Spur	0.366	0.539	0.760	0.945	0.945	0.946	0.946
Vollsperrung	0.426	0.59	0.739	0.993	0.993	0.993	0.993
Sperrung mittlere und rechte Spur	0.456	0.553	0.646	0.996	0.996	0.996	0.996
Sperrung linke und mittlere Spur	0.463	0.586	0.699	0.999	0.999	0.999	0.999
Sperrung linke und rechte Spur	0.395	0.537	0.714	0.999	0.999	0.999	0.999
City							
Sperrung rechte Spur	0	0	0	0	0	0	0
Sperrung mittlere Spur	0	0	0	0	0	0	0
Sperrung linke Spur	0	0	0	0	0	0	0
Vollsperrung	0	0	0	0	0	0.001	0.001
Sperrung mittlere und rechte Spur	0	0	0	0	0	0	0
Sperrung linke und mittlere Spur	0	0	0	0	0	0	0
Sperrung linke und rechte Spur	0	0	0	0	0	0	0
Schwellenwert							
Sperrung rechte Spur	0	0	0.001	0.004	0.004	0.004	0.004
Sperrung mittlere Spur	0	0	0.001	0.002	0.002	0.002	0.002
Sperrung linke Spur	0	0	0	0.001	0.001	0.001	0.001
Vollsperrung	0	0	0.006	0.011	0.011	0.011	0.011
Sperrung mittlere und rechte Spur	0	0	0.002	0.002	0.002	0.002	0.002
Sperrung linke und mittlere Spur	0	0	0	0	0	0	0
Sperrung linke und rechte Spur	0	0	0	0	0	0	0
Incognito							
Sperrung rechte Spur	0.511	0.691	0.854	0.915	0.921	0.923	0.925
Sperrung mittlere Spur	0.512	0.714	0.891	0.944	0.949	0.955	0.956
Sperrung linke Spur	0.442	0.611	0.850	0.954	0.958	0.961	0.962
Vollsperrung	0.606	0.8	0.955	0.98	0.98	0.98	0.98
Sperrung mittlere und rechte Spur	0.668	0.842	0.925	0.95	0.95	0.95	0.95

Sperrung linke und mittlere Spur	0.619	0.826	0.951	0.971	0.971	0.972	0.972
Sperrung linke und rechte Spur	0.612	0.749	0.876	0.969	0.971	0.971	0.971
Fuzzy							
Sperrung rechte Spur	0.074	0.351	0.716	0.863	0.874	0.88	0.88
Sperrung mittlere Spur	0.097	0.37	0.728	0.883	0.891	0.892	0.892
Sperrung linke Spur	0.068	0.281	0.672	0.913	0.919	0.921	0.921
Vollsperrung	0.124	0.478	0.868	0.957	0.958	0.958	0.958
Sperrung mittlere und rechte Spur	0.154	0.574	0.824	0.883	0.886	0.886	0.886
Sperrung linke und mittlere Spur	0.147	0.539	0.868	0.921	0.921	0.921	0.921
Sperrung linke und rechte Spur	0.11	0.465	0.787	0.921	0.944	0.945	0.945

Tabelle C.3.: Detektionsraten der Einfahrt von SWIM, City, Schwellenwert, Incognito und Fuzzy für $\lambda = 90s$ in Abhängigkeit von δ

Anwendungen für routenwahlorientierte Verkehrsinformation





Abbildung C.1.: Vergleich der Detektionsrate für die Erkennung der Einfahrt nach Stärke der Störung für $\lambda = 120s$ in Abhängigkeit von δ

Sperrung	δ						
	0.1km	0.2km	0.4km	0.8km	1.0km	1.5km	2.0km
SWIM L1							
Stärkeklasse 1	0.696	0.874	0.956	0.990	0.990	0.990	0.990
Stärkeklasse 2	0.614	0.812	0.939	0.972	0.972	0.972	0.972
Stärkeklasse 3	0.595	0.795	0.926	0.961	0.961	0.962	0.962
SWIM L2							
Stärkeklasse 1	0.706	0.876	0.957	0.990	0.990	0.990	0.990
Stärkeklasse 2	0.624	0.816	0.939	0.972	0.972	0.972	0.972
Stärkeklasse 3	0.605	0.799	0.926	0.96	0.961	0.962	0.962
SWIM Z1							
Stärkeklasse 1	0.436	0.557	0.688	0.99	0.991	0.991	0.991
Stärkeklasse 2	0.418	0.566	0.726	0.973	0.973	0.973	0.973

Stärkeklasse 3	0.412	0.563	0.724	0.961	0.962	0.962	0.963
----------------	-------	-------	-------	-------	-------	-------	-------

Tabelle C.4.: Detektionsraten der Einfahrt von SWIM für $\lambda = 120s$ in Abhängigkeit von δ nach Reisezeitverlust



(a) Stärkeklasse 1

(b) Stärkeklasse 2

(c) Stärkeklasse 3

Abbildung C.2.: Vergleich der Detektionsrate für die Erkennung der Einfahrt nach Stärke der Störung für $\lambda = 300s$ in Abhängigkeit von δ

Sperrung	δ						
	0.1km	0.2km	0.4km	0.8km	1.0km	1.5km	2.0km
SWIM PA							
Stärkeklasse 1	0.724	0.889	0.967	0.996	0.996	0.996	0.996
Stärkeklasse 2	0.647	0.830	0.948	0.979	0.979	0.979	0.979
Stärkeklasse 3	0.629	0.814	0.938	0.975	0.977	0.977	0.977
SWIM L1							
Stärkeklasse 1	0.696	0.874	0.960	0.993	0.993	0.993	0.993
Stärkeklasse 2	0.614	0.813	0.942	0.977	0.977	0.978	0.978
Stärkeklasse 3	0.595	0.795	0.931	0.974	0.975	0.976	0.976
SWIM L2							
Stärkeklasse 1	0.696	0.877	0.961	0.994	0.994	0.994	0.994
Stärkeklasse 2	0.624	0.816	0.941	0.975	0.976	0.976	0.976
Stärkeklasse 3	0.605	0.799	0.929	0.970	0.972	0.973	0.973
SWIM Z1							
Stärkeklasse 1	0.436	0.559	0.692	0.994	0.995	0.995	0.995
Stärkeklasse 2	0.419	0.567	0.729	0.978	0.978	0.978	0.978
Stärkeklasse 3	0.412	0.564	0.730	0.974	0.975	0.976	0.976

Tabelle C.5.: Detektionsraten der Einfahrt von SWIM für $\lambda = 300s$ in Abhängigkeit von δ nach Reisezeitverlust

Sperrung	δ						
	0.1km	0.2km	0.4km	0.8km	1.0km	1.5km	2.0km

SWIM L1							
Stärkeklasse 1	0.037	0.117	0.538	0.866	0.88	0.91	0.914
Stärkeklasse 2	0.02	0.082	0.505	0.885	0.907	0.932	0.935
Stärkeklasse 3	0.016	0.071	0.497	0.89	0.911	0.939	0.942
SWIM L2							
Stärkeklasse 1	0.037	0.117	0.539	0.866	0.88	0.91	0.914
Stärkeklasse 2	0.020	0.082	0.505	0.883	0.905	0.93	0.933
Stärkeklasse 3	0.016	0.071	0.496	0.887	0.908	0.936	0.938
SWIM Z1							
Stärkeklasse 1	0.038	0.118	0.539	0.865	0.879	0.909	0.913
Stärkeklasse 2	0.02	0.083	0.506	0.885	0.907	0.932	0.935
Stärkeklasse 3	0.016	0.072	0.497	0.89	0.911	0.939	0.942

Tabelle C.6.: Detektionsraten der Ausfahrt von SWIM für $\lambda = 120s$ in Abhängigkeit von δ nach Reisezeitverlust

Sperrung	δ						
	0.1km	0.2km	0.4km	0.8km	1.0km	1.5km	2.0km
SWIM PA							
Stärkeklasse 1	0.038	0.117	0.539	0.868	0.882	0.912	0.916
Stärkeklasse 2	0.02	0.082	0.502	0.885	0.908	0.933	0.936
Stärkeklasse 3	0.016	0.071	0.494	0.891	0.912	0.941	0.943
SWIM L1							
Stärkeklasse 1	0.037	0.117	0.539	0.866	0.881	0.910	0.915
Stärkeklasse 2	0.020	0.082	0.506	0.886	0.908	0.933	0.936
Stärkeklasse 3	0.016	0.071	0.497	0.891	0.913	0.940	0.943
SWIM L2							
Stärkeklasse 1	0.037	0.117	0.539	0.867	0.881	0.911	0.915
Stärkeklasse 2	0.020	0.082	0.505	0.884	0.906	0.931	0.934
Stärkeklasse 3	0.016	0.071	0.497	0.888	0.909	0.937	0.940
SWIM Z1							
Stärkeklasse 1	0.038	0.118	0.539	0.865	0.878	0.910	0.914
Stärkeklasse 2	0.020	0.083	0.506	0.886	0.908	0.933	0.936
Stärkeklasse 3	0.016	0.072	0.498	0.891	0.912	0.940	0.943

Tabelle C.7.: Detektionsraten der Ausfahrt von SWIM für $\lambda = 300s$ in Abhängigkeit von δ nach Reisezeitverlust

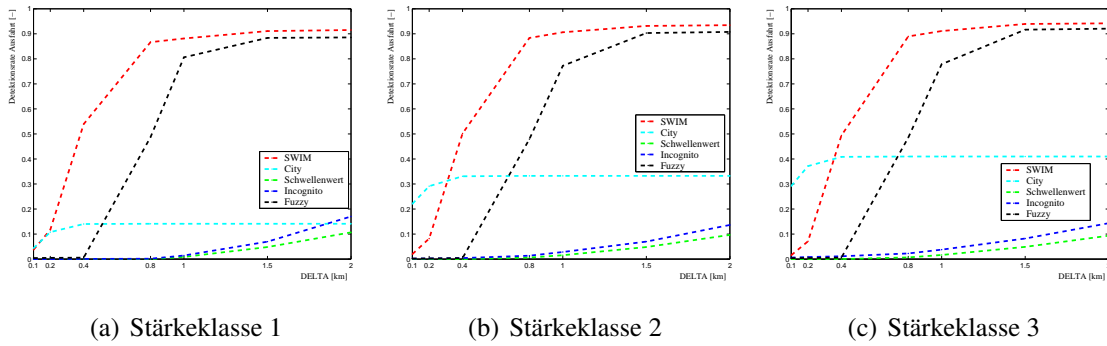


Abbildung C.3.: Vergleich der Detektionsrate für die Erkennung der Ausfahrt nach Stärke der Störung für $\lambda = 120s$

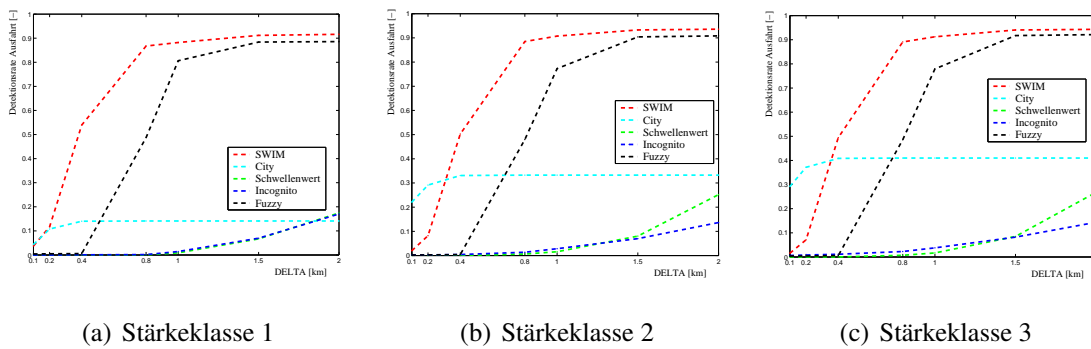


Abbildung C.4.: Vergleich der Detektionsrate für die Erkennung der Ausfahrt nach Stärke der Störung für $\lambda = 300s$ in Abhängigkeit von δ

D. Parameter XFCD-Verfahren

Parameter	Abkürzung
Fuzzy-Algorithmus	
Schwellenwerte für den Indikator s1 und s2	vgrenz
Schwellenwert für Störindex SI	SIgrenz
Parameter alpha für Detektion der Stauausfahrt	alpha
Incognito	
Schwellenwert für Rn	Rngrenz
Schwellenwert für die Unterscheidung der oberen Verkehrsklassen a und a/b	s_fo
Unterscheidung der freien Verkehrsklassen	s_fa
Unterscheidung der Verkehrsklassen c und möglichem Stau	s_fu
Unterscheidung der unteren Verkehrsklassen c und gestaut	s_g
Zeit, die auf eine erneute Staumeldung gewartet wird	warte60
City-Algorithmus	
Zeitintervall	Nzeit
Zurückgelegter Weg	Nweg
Wegbezogene Anzahl der Wechsel in der Beschleunigungsrichtung	Nweg_konst
Zeitbezogene Anzahl der Wechsel in der Beschleunigungsrichtung	Nzeit_konst
Maximale Haltezeit	t_max
Mindestgeschwindigkeitsunterschied	delta_v_extrem
Geschwindigkeitsschranke für Störungsausfahrt	v_zul
Mindestanforderung für den Weg bei der Beschleunigung von 0 auf 40 kmh	l_0_40
Minstdauer des Staus	l_0_40
Mindestanforderung für die Zeit bei der Beschleunigung von 0 auf 40 km/h	a_0_40
Schwellenwertverfahren	
Schwellenwerte für Geschwindigkeitsniveaus	S1,S2
Schwellenwerte für Übergangsbereiche	S3,S4,K1,S5

Tabelle D.1.: Parameter der XFCD-Verfahren Fuzzy, Incognito, City und Schwellenwert

Variable	Definitionsbereich SSI	Definitionsbereich Pelops
Blinker	1 = links 2 = rechts	-1 = links +1 = rechts
Gang	0-253 254 = Rückwärtsgang	1-5 kein Rückwärtsgang oder Leerlauf
Bremspedal	0 = keine Bremsung 1 = Bremse	-1...0 = Bremsen 0...1 = Gasgeben
Licht	2 = Abblendlicht	1 = an 0 = aus
Türentstatus	31 = Tür auf	festgelegt auf 0
Nebel	1 = Nebelscheinwerfer an 2 = Nebelrückleuchte	Sichtbarkeitsvariabel in Metern
Temperatur	in Celsius	konst = 20
Wischer	1 = Regensensor 2 = Intervall 3 = Stufe 1	konstant = 0
Schnee	0 für schneefrei 1 = starker Schneefall	konst als 0
Radeinschlag	-75Grad und +75Grad	bis 4Pi

Tabelle D.2.: Konstante Versuchsvariable

Literaturverzeichnis

OBERSTE BAUBEHÖRDE IM BAYER. STAATSMINISTERIUM DES INNEREN (2002). Straßenverkehrszählung 2000. München.

ASSENMACHER, S. (2005). *diwa - Direkte Information und Warnung für Autofahrer. Untersuchung des derzeitigen Meldungsmanagements*. (Zwischenbericht im Auftrag der BMW AG.) Lehrstuhl für Verkehrstechnik, TU München.

AHMED, M.S. (1983). Stochastic Processes in Freeway Traffic. *Traffic Engineering and Control*, 24.

BANKS, J.H. (2002). Review of Empirical Research on Congested Freeway Flow. *Transportation Research Record. TRB, National Research Council*, Washington, DC.

BAST. (2005). *Bestand zulassungspflichtiger Kfz in Deutschland*. Gefunden am 01.04.06 unter www.bast.de

BAST. (2005). *Fahrleistungen in Deutschland nach Kraftfahrzeugarten*. Gefunden am 01.04.06 unter www.bast.de

BELZNER, H. (2002). *Ein hybrides Modell zur Kurzfristprognose lokaler Verkehrsgrößen*. Diplomarbeit, Zentrum Mathematik, Technische Universität München.

BELZNER, H., BOGENBERGER, K. UND R. KATES (2003). A Hybrid Model for Forecasting Local Traffic Parameters. *10th IFAC Symposium on Control in Transportation Systems*, Tokyo, Japan.

BERTINI, R.L. (O.D.). *Congestion and Its Extent*. Gefunden am 07.04.06 unter http://www.its.pdx.edu/pdf/bertini_congestion_May_2005.pdf

BERTINI, R.L. (2005). *Congestion and Its Extent*. Vortrag am 28.Juni 2005, Imperial College, London.

BLACK, J. UND I.SREEDEVI (2001). Automatic Incident Detection Algorithms. *ITS Decision Report*, Gefunden am 20.11.02 unter www.path-berkeley.edu

BMW AG. (2003). *Detaillierte Analyse individueller Dienste*. Studie, München.

BOGENBERGER, K. (2003). Qualität von Verkehrsinformationen. *Straßenverkehrstechnik 10*, S.518-526.

BOGENBERGER, K., BERTINI, R.L. UND S. BOICE (2006). Analytische Methoden zur Interpretation von Verkehrsdaten. *Straßenverkehrstechnik* (eingereicht).

- BOGENBERGER, K., HASS, B. UND A. HEUCKE (2006). Nutzung von Verkehrsinformationsdiensten - Eine empirische Untersuchung des Routenwahlverhaltens am Beispiel BMW ASSIST. *Internationales Verkehrswesen* (im Erscheinen).
- BOGENBERGER, K. UND R. KATES (2002). *Eine makroskopische Methode zur Bewertung der Qualität individueller Verkehrsdienste*. Interner Bericht der BMW AG, München.
- BOX, G.E.P. UND G.M. JENKINS (1976). *TIME SERIES ANALYSIS forecasting and control*. Holden Day Inc., San Francisco.
- BOX, G.E.P., JENKINS G.M. UND G.C. REINSEL (1994). *Time Series Analysis: Forecasting and Control*. Prentice-Hall, New Jersey.
- BREITENBERGER, S. (1997). *Einschätzung aktueller Verkehrszustände aus fahrzeuggenerierten Daten*. Diplomarbeit, Fachgebiet Verkehrstechnik und Verkehrsplanung, Technische Universität München.
- BREITENBERGER, S., GRÜBER, B. UND M. NEUHERZ (2004). Extended Floating Car Data - Potenziale für die Verkehrsinformation und notwendige Durchdringungsraten. *Straßenverkehrstechnik 10*, S.522-531.
- BREITENBERGER, S. UND M. HAUSCHILD (2004). *Floating Phone Data*. Internes Arbeitspapier, BMW AG München.
- BUREAU OF TRANSPORTATION STATISTICS (2005). *Passenger Car and Motorcycle Fuel Consumption and Travel*. Gefunden am 08.04.06 unter http://www.bts.gov/publications/national_transportation_statistics/2005/html/table_04_11.html
- BUSCH, F. (1986). *Automatische Störungserkennung auf Schnellverkehrsstraßen - ein Vergleich*. Dissertation, Universität Karlsruhe.
- BUSCH, F. (1991). Incident Detection. In: Markos Papageorgiou (Eds), *Concise Encyclopedia of TRAFFIC & TRANSPORTATION SYSTEMS*. Pergamon Press.
- BUSCH, F. UND A. GHIO (1994). *Automatische Störfallerkennung auf Autobahnen mit Hilfe von Fuzzy-Logik*. Siemens AG, München.
- CASSIDY, M.J. UND R. BERTINI (1999). Some Traffic Features at Freeway Bottlenecks. *Transportation Research*, Vol.33B, S.25-42.
- CHEU, R.L., QI, H. UND D.H. LEE (2002). A Mobile Sensor and Sensor-Based Algorithm for Freeway Incident Detection. *Transportation Research Record*, National Academy Press, Washington, D.C.
- CHRISTEN, F. (2004). *Technische Dokumentation zur Einbindung externer IC-Regler in das Simulationsprogramm PELOPS*. fka, Aachen.
- DAGANZO, C.F., CASSIDY, M.J. UND R.L. BERTINI (1999). Possible Explanations of Phase Transitions in Highway Traffic. *Transportation Research A*, Volume 33, S.365-379.

DEMIR, C., KERNER, B.S., HERRTWICH, R.G., KLENOV, S.L., REHBORN, H., ALEKSIC, M., REIGBER, T., SCHWAB, M. UND A. HAUG (2003). FCD for Urban Areas: Method and Analysis of Practical Realisations. *Proceedings of the 8th World Congress on Intelligent Transport Systems*, Madrid.

DOUGHERTY, M., CHEN, H. UND F. MONTGOMERY (1998). Principle Components Analysis Based Incident Detection. *Proc. 5th International Conference of Advanced Technologies in Transportation*, Newport Beach, California.

DOUGHERTY, M.S., KIRBY, H.R. UND R.D. BOYLE (1993). The use of neural networks to recognise and predict traffic congestion. *Traffic Engineering and Control*, S.311-314.

DUDEK, C.L., MESSER, C.J. UND N.B. NUCKLES (1974). Incident Detection on Urban Freeways. *Transportation Research Record 495. TRB, National Research Council*, Washington, DC.

EDIE, L.C. (1961). Car-Following and Steady-State Theory for Noncongested Traffic. *Operations Research*, Vol.9, S.66-76.

Forschungsgesellschaft für Straßen- und Verkehrswesen eV (FGSV) (2001). *Handbuch zur Bemessung von Straßenverkehrsanlagen*, Köln.

FRANK, D. UND J. SUMPFF (1997). *Abschätzung der volkswirtschaftlichen Verluste durch Stau im Straßenverkehr*. Studie, BMW AG, München.

GARTNER, N.H., MESSER, C.J. UND A. RATHI (1992). *Traffic Flow Theory*. Überarbeitung und Erweiterung des Transportation Research Board Special Report 165. Gefunden am 07.04.06 unter <http://www.tfhrc.gov/its/tft/tft.htm> (Originalwerk publiziert 1975)

GAZIS, D.C., HERMAN, R. UND R. ROTHERY (1961). Nonlinear Follow-The-Leader Models of Traffic Flow. *Operations Research*, Vol.9, S.545-567.

GÖSSEL, F., WRASE, B. UND E. MICHLER (2001). Neue Ansätze zur fahrzeuggenerierten Verkehrsdatengewinnung in urbanen Regionen: Processing, Analyse und Qualifizierung von Floating-Car-Daten. *Proceedings of the 18th Dresden Conference on Traffic & Transportation Sciences*, Dresden.

GREENSHIELDS, B.D. (1935). A study in highway capacity. *Highway Research Board Proc. 14*.

GRÜBER, B., UND A. HOLZ (2003). Verkehrsdatenerfassung aus der Luft. *Internationales Verkehrswesen*, Nr.3, S.93-96.

GUGGENMOOS-HOLZMANN, I. (1997). Medizinische Biometrie. In H.-J. Seelos (Hrsg.), *Medizinische Informatik, Biometrie und Epidemiologie*, de Gruyter Lehrbuch, Berlin.

HARTWIG, K. (2001). *Einschätzung von städtischen Verkehrslagen aus fahrzeuggenerierten Daten unter Minimierung der Übertragungskosten*. Diplomarbeit, Technische Universität Dresden.

- HAUSCHILD, M. (2003). *Echtzeit-Verarbeitung von Fahrzeug-Bus-Daten zur Ereigniserkennung im öffentlichen Straßennetz*. Diplomarbeit, Fachhochschule Aachen.
- HELBING, D. UND M. TREIBER (2002). Critical Discussion of „Synchronized Flow“. *Cooperative Transportation Dynamics 1*, 2.12.24.
- HELLINGA, B. UND G. KNAPP (2000). AVI Based Freeway Incident Detection. *Transportation Research Record 1727*. National Academy Press, Washington, D.C., S.142 - 153.
- HOCHSTÄDTER, A., ZAHN, P. UND K. BREUER (2000). Ein universelles Fahrermodell mit den Einsatzbeispielen Verkehrssimulation und Fahrsimulator. *9. Aachener Kolloquium Fahrzeug- und Motorentchnik*.
- HOLLAND, J.H. (1975). *Adaptation in natural and artificial systems*. The University of Michigan Press, Ann Arbor.
- HOLZ, A. (2005). *Verkehrsmonitoring mit Hilfe von Radarfernerkundung*. Dissertation, Universität Mainz.
- HOOPS, M., KATES, K. UND KELLER, H. (1999). Bewertung von Verfahren zur Erkennung von Störungen im Verkehrsablauf in Theorie, Praxis und Simulation. Endbericht im Auftrag des Bundesministeriums für Verkehr, Bau- und Wohnungswesen, Forschungsvorhaben FE 3.289, Technische Universität München.
- HORTER, S., KATES, R., MEIER, J., UND H. WEHLAN (2004). Traffic Data Fusion and Sensor Fault Detection Using Traffic Flow Modelling. *Proceedings of the 10th World Congress on Intelligent Transport Systems*, Madrid.
- HÜBNER, J. (2005). *Gefahrenwarnungen im Verkehr und ihre Umsetzung im digitalen Medium*. Magisterarbeit, Ludwig-Maximilians Universität München.
- HUBER, W. (2001). *Fahrzeuggenerierte Daten zur Gewinnung von Verkehrsinformationen*. Dissertation, Veröffentlichung des Fachgebiets Verkehrstechnik und Verkehrsplanung, Technische Universität München.
- INVENT-BÜRO (2002) *Verkehrsleistungsassistentz VLA. Kurzdarstellung des Teilprojekts VLA* [Broschüre]. Gefunden am 13.03.06 unter <http://www.invent-online.de/downloads/VLA-handout-D.pdf>.
- ISHIDA, H., FURUYA, H., KAI, S. UND N. OKAMOTO (2003). Travel Speed and Traffic Congestions Recognition on Expressways. *Journal of the Eastern Asia Society for Transportation Studies*, Vol.5.
- MINISTRY OF INTERNAL AFFAIRS AND COMMUNICATIONS, STATISTICS BUREAU (2005). *Japan Statistical Yearbook*. Gefunden am 08.04.06 unter www.stat.go.jp
- JIN, X., CHEU, R.L. UND D. SRINIVASAN (2002). Development and adaptation of constructive probabilistic neural network in freeway incident detection. *Transportation Research Part C 10*, S.121-147.

KAMARIANAKIS, Y., UND P. PRASTACOS (2003). Forecasting Traffic Flow Conditions in an Urban Network: Comparison of Multivariate and Univariate Approaches. *Transportation Research Record 1857*, S.74-84.

KATES, R. UND K. BOGENBERGER (2004). Potential for improved traffic performance using inter-vehicle communication and distributed intelligence. *Proceedings of the 10th World Congress on Intelligent Transport Systems*, Madrid.

KATES, R., BELZNER, H., HOCHSTÄDTER, A. UND G. LERNER (2006). Flow stabilization and enhanced traffic performance using inter-vehicle communication and distributed intelligence. *Proceedings of the 13th World Congress on Intelligent Transport Systems*, London.

KATES, R., BOGENBERGER, K. UND M. HOOPS (1998). Mesoscopic Simulation with ANIMAL: Optimal Utilization of Downstream Traffic Detector Data and the Propagation of Information. In: Schreckenberg M. und D.E. Wolf (Hrsg.), *Traffic and Granular Flow '97*, Springer-Verlag, S.453-467.

KATES, R., KELLER, H. UND G. LERNER (1999). Measurement-based prediction of safety performance for a prototype traffic warning system. *Proceedings of the Conference on Traffic Safety on Two Continents*, Malmö, Schweden.

KELLER, H. (2002). Skriptum Verkehrstechnik 2, Fachgebiet Verkehrstechnik und Verkehrsplanung, Technische Universität München.

KELLER, H. (2002). Skriptum Verkehrsleitsysteme im Straßenverkehr, Fachgebiet Verkehrstechnik und Verkehrsplanung, Technische Universität München.

KERNER, B.S., REHBORN, H. UND M. ALEKSIC (1999). Forecasting of Traffic Congestion. In: Helbing, D., Herrmann, H.J., Schreckenberg, M. und D.E. Wolf (Hrsg.), *Traffic and Granular Flow '99*, S.339-344, Springer-Verlag.

KERNER, B.S. (2002). Empirical macroscopic features of spatial-temporal traffic patterns at highway bottlenecks. *Physical Review E, Volume 65, 046138*, The American Physical Society.

KERNER, B.S., REHBORN, H., HAUG, A. UND M. ALEKSIĆ (2003). *Comparison of AS-DA/FOTO application for tracing of spatial-temporal congested patterns on freeways*. Vortrag Daimler-Chrysler in INVENT NIV, Esslingen.

KERNER, B.S. (2004). *The Physics of Traffic*. Springer-Verlag Berlin Heidelberg.

KIM, Y. (2002). *Online Traffic Flow Model Applying Dynamic Flow-Density Relations*. Dissertation, Fachgebiet Verkehrstechnik und Verkehrsplanung, Technische Universität München.

KIM, Y. UND H. KELLER (2001). Zur Dynamik zwischen den Verkehrszuständen im Fundamentaldiagramm. *Straßenverkehrstechnik 9*, S. 433-442.

KIMBAUER, M. (O.D.). *McMaster Algorithm*. Gefunden am 08.01.2006 unter <http://www.mcmaster.ca/graduate/flhall/macalg.html>

- KONDURI, S., UND K.C. SINHA (2002). Statistical Models for Prediction of Freeway Incidents. *Proceedings of the 7th International Conference on Applications of Advanced Technology in Transportation*, Cambridge, Massachusetts.
- KOSHI, M., IWASAKI, M. UND I. OHKURA (1983). Some findings and an overview on vehicular flow characteristics. *Proceedings of the 8th International Symposium on Transportation and Traffic Theory*, S.403-451, Toronto, Canada.
- LAPIERRE, R. UND G. STEIERWALD (1987). *Verkehrsleittechnik für den Straßenverkehr*. Band 1. Springer-Verlag, Berlin Heidelberg.
- LEONHARDT, A. (2006). *Erweitertes Verfahren zur Ermittlung und Prognose von Reisezeiten auf Basis von Taxi FCD*. Internes Arbeitspapier, Technische Universität München.
- Leit- und Informationssystem Berlin*. Schlussbericht, Berlin 1991.
- LEVIN, M. UND G. KRAUSE (1979). Incident-Detection Algorithms, Part I. Off-line Evaluation. *Transportation Research Record 722*, TRB, National Research Council, Washington D.C.
- LIGHTHILL, M.J., UND G.B. WITHAM (1955). On kinematic waves II. A theory of traffic flow on long crowded roads. *Proceedings Royal Society*, 229A, S.317-345, London.
- LIN, W.-H. UND C.F. DAGANZO (1997). A Simple Detection Scheme for Delay-Inducing Freeway Incidents. *Transportation Research A*, Volume 31, S.141-155.
- MAY, A.D. UND H.M. KELLER (1968). Evaluation of Single- and Two-Regime Traffic Flow Models. *Straßenbau und Straßenverkehrstechnik*, 86, S.37-47, Bonn.
- MARTIN, P.T., PERRIN, J., HANSEN B., KUMP, R. UND D. MOORE (2001). *Incident Detection Algorithm Evaluation*. Final Report. Angefertigt für Utah Department of Transportation. Gefunden am 07.04.06 unter http://www.ndsu.nodak.edu/ndsu/ugpti/MPC_Pubs/html/MPC01-122.html
- MEIER, J., KATES, R. LERNER, G. UND H. WEHLAN (2001). Evaluation of the Model-Based Automatic Incident Detection Algorithm AZTEK at the A92 Telematics Test Site. *Proceedings of the 8th World Congress on Intelligent Transport Systems*, Sydney.
- MUÑOZ, J.C. UND C.F. DAGANZO (2002). Fingerprinting Traffic From Static Freeway Sensors. *Cooperative Transportation Dynamics*, 1,1-11.
- NEWELL, G.F. (1993). A Simplified Theory of Kinematic Waves in Highway Traffic, Part I: General Theory. *Transportation Research B*, Volume 27B, S.281-287.
- OBERT, G. (2005). *Lokale Gefahrenwarnung*. Spezifikation der Projekte DIWA und Mobile.Info, BMW AG, München.

- OKAMURA, H., WATANABE, S., UND T. WATANABE (2000). An Empirical Study on the Capacity of Bottlenecks on the Basic Suburban Expressway Sections in Japan. *4th International Symposium on Highway Capacity*, Maui, USA.
- OZBAY, K. UND P. KACHROO (1999). *Incident Management in Intelligent Transportation Systems*. Artech House, Norwood.
- PETTY, K.F., SKABARDONIS, A., UND P.P. VARAIYA (1997). Incident Detection with Probe Vehicles: Performance, Infrastructure Requirements, and Feasibility. *Proceedings of 8th IFAC Symposium on Transportation Systems*, Chania, Greece, Volume 1, 125-130.
- PERSAUD, B.N., UND F. HALL (1989). Catastrophe Theory and Patterns in 30-Second Freeway Traffic Data - Implications for Incident Detection. *Transportation Research Part A*, Volume 23, S.103-113.
- POHLHEIM, H. (2000). *Evolutionäre Algorithmen*. Springer-Verlag, Berlin Heidelberg.
- QI, H., CHEU, R.L., UND D.-H. LEE (2002). Freeway Incident Detection Using Kinematic Data From Probe Vehicles. *Proceedings of the 9th World Congress on Intelligent Transportation Systems*, ITS America.
- RICHARDS, P.I. (1956). Shockwaves on the highway. *Operations Research*, 4, S.42-51.
- RITCHIE, S.G. UND B. ABDULHAI (1997). Development Testing and Evaluation of Advanced Techniques for Freeway Incident Detection. California PATH Working Paper, Report for MOU 138.
- SARVI, M., HORIGUCHI, R., KUWAHARA, M., SHIMIZU, Y., SATO, A. UND Y. SUGISAKI (20). *A Methodology to Identify Traffic Condition Using Intelligent Probe Vehicles*. Gefunden am 07.04.06 unter <http://www.transport.iis.u-tokyo.ac.jp/PDFs/2003/2003-021.pdf>
- SCHÄFER, R.-P., THIESSENHUSEN, K.-U. UND P. WAGNER (2002). A Traffic Information System by Means of Real-Time Floating-Car Data. *Proceedings of the ITS World Congress*, Chicago, USA.
- SCHLAICH, J. (2005). Nutzungsmöglichkeiten von Floating Phone Data. *9. Fachkolloquium Straße und Verkehr*, Stuttgart. Gefunden am 22.04.06 unter http://www.uni-stuttgart.de/isv/vuv/publication/PDF_fachkolloquium_2005/Fachkolloquium_2005.pdf
- SCHNÖRR, C. (2000). Von der Meßwerterfassung bis zu automatisch generierten Verkehrsmeldungen. *Straßenverkehrstechnik 1*, S.11-18.
- SCHÖNHOF, M., UND D. HELBING (2004). Empirical Features of Congested Traffic States and Their Implications for Traffic Modeling. *Transportation Science*, submitted. Gefunden am 06.04.06 unter www.helbing.org
- SCHÜTTE, C., BOGENBERGER, K. UND O. ERNHOFER (1999). Analyse der Verkehrsqualität mit innovativer Datenerfassung - Beispiel Mittlerer Ring München. *Straßenverkehrstechnik*, 5, S.212-219.

- SMITH, B.L. UND M.J. DEMETSKY (1994). Short-Term Traffic Flow Prediction: Neural Network Approach. *Transportation Research Record 1453*, S.98-104.
- SOLOMON, M. (1991). A Review of Automatic Incident Detection Techniques. *Draft, ADVANCE Programme Technical Report*, USA.
- SRINIVASAN, D., CHEN, R.L. UND Y.P. POH (2001). Hybrid Fuzzy-Logic-Genetic Algorithm Technique for Automated Detection of Traffic Incidents on Freeways. *IEEE International Transportation Systems Conference Proceedings*, Oakland, USA.
- STATISTISCHES BUNDESAMT (2005). *Deutschland im internationalen Vergleich 2005*. Wiesbaden.
- STEPHANEDES, Y.J. UND A.P. CHASSIAKOS (1993). Freeway Incident Detection Through Filtering. *Transportation Research C*, Vol.1, No.3, S.219-233.
- STÖRUNG (2006). In *Wikipedia* Gefunden am 10.03.2006 unter <http://de.wikipedia.org/wiki/St%C3%B6rung>.
- TARKO, A. UND N. ROUPHAIL (1993). Travel Time Data Fusion in ADVANCE. *Proceedings ASCE Third Annual International Conference on Applications of Advanced Technologies in Transportation (AATT)*, Vol. I, Seattle, Washington.
- THE WORLD FACTBOOK (2005). Gefunden am 08.04.06 unter www.cia.gov/cia/publications/factbook/fields/2085.html
- THOMAS, K., DIA, H. UND N. COTTMAN (2001). Simulation of Arterial Incident Detection Using Neural Networks. *Proceedings of the 8th World Congress on Intelligent Transport Systems*, Sydney.
- TENG, H. UND Y. QI (2003). Detection-delay-based freeway incident detection algorithms. *Transportation Research Part C*, Volume 11C, S.265-287.
- TENG, H. UND Y. QI (2003). Application of wavelet technique to freeway incident detection. *Transportation Research Part C*, Volume 11C, S.289-308.
- BUNDESMINISTERIUM FÜR VERKEHR, BAU UND STADTENTWICKLUNG (2004). *Telematik im Verkehr - Entwicklungen und Erfolge in Deutschland*. Bonn.
- Zwischenbericht Verkehrsleistungsassistenz - Konzepte zur Verkehrsleistungssteigerung*. Bericht zum 5. Meilenstein 2004.
- WARDROP, J.G. (1952). Some Theoretical Aspects of Road Traffic Research. *Proceedings of the Institute of Civil Engineers*, Part 2, 1, S.325-378.
- WESTERMAN, M., LITJENS, R. UND J.-P. LINNARTZ (1996). Integration of Probe Vehicle and Induction Loop Data - Estimation of Travel Times and Automatic Incident Detection. *California PATH Research Report*, Berkeley, USA.

WIEDEMANN, R. (1974). Simulation des Straßenverkehrsflusses. *Schriftenreihe des Instituts für Verkehrswesen der Universität Karlsruhe*, Heft 8.

XIE, C. UND E. PARKANY (2002). Use of Driver-Based Data for Incident Detection. *Proceedings of the 7th International Conference on Applications of Advanced Technology in Transportation*, Cambridge, Massachusetts.

YUAN, F., UND R.L. CHEU (2003). Incident detection using support vector machines. *Transportation Research Part C*, Volume 11C, S.309-328.

ZHANG, M. Y., BLOSSEVILLE J.M., MOTYKA, V. UND J. LATERRASSE (1994). Automatic Congestion Detection (ACD) on Urban and Suburban Expressway Networks. *7th IFAC/IFORS Symposium on Transportation Systems*, Volume III, China.

ZOU, X., UND D. LEVINSON (2003). Detecting the Breakdown of Traffic. *Transportation Research Board 2003 Annual Meeting*.