

Technische Universität München

Fakultät für Maschinenwesen

Lehrstuhl für Fahrzeugtechnik

**Prädiktive Kritikalitätsschätzung  
für aktive Fahrzeugsicherheitsfunktionen  
mit Machine Learning Verfahren**

Johannes Wallner, M. Sc.

Vollständiger Abdruck der von der Fakultät für Maschinenwesen der  
Technischen Universität München zur Erlangung des akademischen Grades eines

**Doktor-Ingenieurs**

genehmigten Dissertation.

Vorsitzender: Prof. Dr.-Ing. Boris Lohmann  
Prüfer der Dissertation: 1. Prof. Dr.-Ing. Markus Lienkamp  
2. Prof. Dr. Daniel Straub

Die Dissertation wurde am 05.09.2019 bei der Technischen Universität München eingereicht  
und durch die Fakultät für Maschinenwesen am 03.02.2020 angenommen.



# Danksagung

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Fahrzeugtechnik der Technischen Universität München in den Jahren 2014 bis 2017 im Rahmen eines INI.TUM Kooperationsprojektes mit der AUDI AG in der Abteilung für vorausschauende Sicherheitsfunktionen.

Ganz besonders möchte ich mich bei meinem Doktorvater Prof. Dr.-Ing. Markus Lienkamp bedanken, der die Arbeit mit fachlichen Anregungen, entgegengebrachtem Vertrauen sowie dem Schaffen einer freien und selbstbestimmten Arbeitsumgebung hervorragend betreut hat.

Ebenfalls bedanke ich mich bei Prof. Dr. Daniel Straub für die Zweitprüfung. Weiterhin gilt mein Dank Herrn Prof. Dr.-Ing. habil. Boris Lohmann für die Übernahme des Prüfungsvorsitzes.

Ein herzlicher Dank geht an meinen Betreuer der AUDI AG, Dr.-Ing. Sebastian Engel, der jederzeit eine große Hilfe in fachlichen und organisatorischen Themen war. Ich möchte mich ebenfalls bei Herrn Dr.-Ing. Frank Diermeyer bedanken, der als Gruppenleiter am Lehrstuhl die Entstehung der Arbeit unterstützt und mit fachlicher Hilfe begleitet hat.

Meinen Korrekturlesern Sophia Wallner, David Wittmann, Johannes Feiler, Dr.-Ing. Sebastian Engel und Dr.-Ing. Frank Diermeyer danke ich für ihre investierte Zeit und die vielen hilfreichen Anregungen.

Allen Kollegen und Freunden am Lehrstuhl für Fahrzeugtechnik möchte ich für die schöne gemeinsame Zeit danken. Die fachlichen Diskussionen, intensiven Doktorandenkolloquien und die vielen kleinen, den Arbeitsalltag bereichernden Heiterkeiten werden mir immer in bester Erinnerung bleiben.

Ein großes Dankeschön gilt allen von mir betreuten Studenten, die durch Engagement und anregende Diskussionen das Forschungsvorhaben unterstützt haben. Insbesondere möchte ich Egon Ye, Johannes Feiler und Thomas Einmüller danken, die einen maßgeblichen Beitrag für diese Arbeit geleistet haben.

Ein ganz besonderer Dank gebührt meinen Eltern, die mir das Studium ermöglicht und mich während meines gesamten Lebens bedingungslos unterstützt haben. Der größte Dank gilt meiner Frau Sophia, die mir in schwierigen Zeiten des Promotionsvorhabens zur Seite stand und mir immer wieder die schönen Seiten des Lebens zeigt.

Garching, im Juli 2019

Johannes Wallner



# Inhaltsverzeichnis

Abkürzungsverzeichnis .....	VII
Formelzeichen .....	IX
<b>1 Einleitung und Motivation.....</b>	<b>1</b>
<b>2 Stand der Wissenschaft.....</b>	<b>3</b>
<b>2.1 Daten von Fahrten im Straßenverkehr.....</b>	<b>3</b>
2.1.1 Verfügbare Datenquellen .....	3
2.1.2 Extraktion relevanter Szenarien .....	5
2.1.3 Bemessung der Kritikalität.....	7
<b>2.2 Retrospektive Bestimmung langsam veränderlicher Einflussfaktoren auf die Unfallwahrscheinlichkeit .....</b>	<b>8</b>
2.2.1 Langsam veränderliche Einflussfaktoren aus Unfalldatenbanken .....	9
2.2.2 Langsam veränderliche Einflussfaktoren aus Studiendaten .....	11
2.2.3 Methoden zur retrospektiven Bestimmung von Einflussfaktoren.....	13
<b>2.3 Prädiktive Schätzung der Unfallwahrscheinlichkeit aufgrund schnell veränderlicher Einflussfaktoren.....</b>	<b>15</b>
<b>3 Diskussion des Stands der Wissenschaft und Idee der Arbeit .....</b>	<b>19</b>
<b>3.1 Diskussion des Stands der Wissenschaft und Ableitung von Forschungsfragen.....</b>	<b>19</b>
<b>3.2 Aufbau und Idee der Arbeit .....</b>	<b>21</b>
<b>4 Quantifizierung langsam veränderlicher Einflussfaktoren.....</b>	<b>25</b>
<b>4.1 Stand der Wissenschaft: Eventdaten der SHRP2 Studie .....</b>	<b>25</b>
<b>4.2 Datenvorverarbeitung .....</b>	<b>27</b>
<b>4.3 Vorgehen: Odds Ratio Analyse .....</b>	<b>27</b>
4.3.1 Bilden von Teilmengen.....	28
4.3.2 Annahmen und Berechnung.....	28
<b>4.4 Ergebnis: Langsam veränderliches Kritikalitätsmaß.....</b>	<b>31</b>
4.4.1 Umwelt.....	31
4.4.2 Fahrerzustand und Fahrmanöver .....	32
<b>4.5 Diskussion.....</b>	<b>35</b>
4.5.1 Anwendungsmöglichkeiten der Ergebnisse.....	35
4.5.2 Datenerhebungsaufwand eines OEM mit Fahrzeugflotte.....	36

4.5.3	Ausblick einer zeit- und ortsbasierten Analyse .....	37
<b>5</b>	<b>Prädiktive Kritikalitätsschätzung von Unfallsequenzen mit maschinellem Lernen .....</b>	<b>39</b>
<b>5.1</b>	<b>Stand der Wissenschaft: Zeitreihendaten der SHRP2 Studie .....</b>	<b>39</b>
<b>5.2</b>	<b>Datenvorverarbeitung .....</b>	<b>43</b>
5.2.1	Zeitreihendaten .....	43
5.2.2	Weiterverwendung langsam veränderlicher Kritikalitätsmaße.....	44
<b>5.3</b>	<b>Vorgehen: Klassifikation der Datensequenzen.....</b>	<b>44</b>
5.3.1	Stand der Wissenschaft: Methoden maschinellen Lernens zur Klassifikation ..	46
5.3.2	Verwendete Datensatzkombinationen .....	55
5.3.3	Erzeugung von entscheidungsrelevanten Merkmalen .....	58
5.3.4	Merkmalsauswahl .....	63
5.3.5	Parametrisierung und Detaillierung der verwendeten Klassifikationsmethoden.....	66
5.3.6	Auswahl der Bewertungsgröße .....	68
5.3.7	Auswertung .....	71
<b>5.4</b>	<b>Ergebnisse und Diskussion .....</b>	<b>73</b>
5.4.1	Random Forest Modelle für festgelegte Zeitfenster vor einem Ereignis.....	73
5.4.2	Kontinuierliche Zeitreihenklassifikation mit einem Random Forest Modell .....	79
5.4.3	Vergleich mit Support Vector Machine .....	85
<b>6</b>	<b>Diskussion und Ausblick.....</b>	<b>89</b>
<b>6.1</b>	<b>Einordnung der Ergebnisse bezüglich der gestellten Forschungsfragen ....</b>	<b>89</b>
<b>6.2</b>	<b>Einordnung der Ergebnisse bezüglich der verwendeten Datenbasis .....</b>	<b>91</b>
<b>6.3</b>	<b>Ausblick.....</b>	<b>92</b>
6.3.1	Weiterverwendung des Informationsmehrerts.....	92
6.3.2	Transfer der Methode auf andere Anwendungsfälle .....	94
<b>7</b>	<b>Zusammenfassung.....</b>	<b>97</b>
	<b>Abbildungsverzeichnis .....</b>	<b>i</b>
	<b>Tabellenverzeichnis .....</b>	<b>iii</b>
	<b>Literaturverzeichnis .....</b>	<b>iv</b>
	<b>Vorveröffentlichungsliste .....</b>	<b>xiii</b>
	<b>Anhang.....</b>	<b>xv</b>

# Abkürzungsverzeichnis

ABS	Antiblockiersystem
ACC	Adaptive Cruise Control ( <i>engl.</i> ), Abstandsregeltempomat
AdaBoost	<b>Adaptive Boosting</b> ( <i>engl.</i> ), Meta-Algorithmus zum maschinellen Lernen
ANB	Automatische Notbremse
ASIL	Automotive Safety Integrity Level ( <i>engl.</i> ), Risikoklassifizierungsschema der Norm ISO 26262
ASR	Antischlupfregelung
aTTC	TTC zum Vorderfahrzeug unter Berücksichtigung der Relativbeschleunigung
AUC	Area Under Curve ( <i>engl.</i> ), Fläche unter der Kurve
Bagging	<b>Bootstrap Aggregation</b> ( <i>engl.</i> ), Methode zur Vorhersage aus verschiedenen Regressions- oder Klassifikationsmodellen
bzw.	beziehungsweise
ca.	circa
CART	Classification and Regression Tree ( <i>engl.</i> ), Algorithmus zur Erzeugung eines Entscheidungsbaums
ConvNet	Convolutional Neural Network ( <i>engl.</i> ), faltendes, künstliches neuronales Netz
Cov	Kovarianz (stochastisches Maß)
ESP	Elektronisches Stabilitätsprogramm
exp	Exponentialfunktion
FAS	Fahrerassistenzsystem
FCART	Fuzzy Classification and Regression Tree
FN	Falsch negativ, Fehler 2. Art, fälschlicherweise ausbleibender Alarm
FOT	Field Operational Test ( <i>engl.</i> ), Feldversuch zur Untersuchung der Wirkung von Fahrerassistenzsystemen
FP	Falsch positiv, Fehler 1. Art, Falschalarm
FPR	Falsch-positiv-Rate
FFT	Diskrete Fouriertransformation
GEN	Treffergenauigkeit
GPS	Global Positioning System ( <i>engl.</i> ), globales Positionsbestimmungssystem
HC	Heading Control ( <i>engl.</i> ), Spurhalteassistent
IMU	Inertial Measurement Unit ( <i>engl.</i> ), inertielle Messeinheit
inv	Inverse
iqr	Interquartilabstand
ISO	Internationale Organisation für Normung
kNN	Künstliches neuronales Netz
Lkw	Lastkraftwagen
mad	Mittlere absolute Abweichung vom Medianwert
mean	Arithmetischer Mittelwert
ML	Machine Learning ( <i>engl.</i> ), Maschinelles Lernen

NDS	Naturalistic Driving Study ( <i>engl.</i> ), Naturalistische Fahrverhaltensbeobachtung
OBD	On Board Diagnose
OEM	Original Equipment Manufacturer ( <i>engl.</i> ), Fahrzeughersteller
OR	Odds Ratio
RBF	Radiale Basisfunktion
RN	Richtig negativ
ROC	Receiver Operating Characteristic ( <i>engl.</i> )
RP	Richtig positiv
RPR	Richtig-positiv-Rate
RR	Relatives Risiko
SHRP2	Strategic Highway Research Program 2
SL	Speed Limiter ( <i>engl.</i> ), Geschwindigkeitsbegrenzer
std	Standardabweichung zur Merkmalerzeugung
SUV	Sport Utility Vehicle ( <i>engl.</i> ), Geländelimousinen
SVM	Support Vector Machine
THW	Time Head Way ( <i>engl.</i> ), Zeitlücke
TTC	Time To Collision ( <i>engl.</i> ), Zeit bis zur Kollision
TTR	Time To React ( <i>engl.</i> ), Zeit, um zu reagieren
z. B.	Zum Beispiel



# Formelzeichen

Formelzeichen	Einheit	Beschreibung
$\alpha$	-	Signifikanzniveau (auch: Irrtumswahrscheinlichkeit) des Konfidenzintervalls
$\alpha_i$	-	Lagrange-Multiplikatoren
$\Delta i(N, s)$	-	Differenz von Unreinheitsmaßen zur Splitbewertung des Knotens $N$
$\Delta l_{min}$	-	Minimale Verbesserung des Unreinheitsmaßes an einem Knoten
$\epsilon$	-	Tolerierte Abweichung für die Schätzung eines Odds Ratios durch ein $(1-\alpha)\%$ -Konfidenzintervall
$\sigma$	-	Kernelparameter
$\Phi$	-	Abbildung in einen höherdimensionalen Raum $\mathcal{H}$
$\dot{\psi}$	grad/s	Gierrate
$\ddot{\psi}$	grad/s <sup>2</sup>	Gierbeschleunigung
$a$	-	Anzahl der exponierten Krankheitsfälle/Unfälle
$a_x$	m/s <sup>2</sup>	Fahrzeugbeschleunigung in longitudinaler Richtung
$a_y$	m/s <sup>2</sup>	Fahrzeugbeschleunigung in lateraler Richtung
$a_z$	m/s <sup>2</sup>	Fahrzeugbeschleunigung in vertikaler Richtung
$b$	-	Anzahl der nicht exponierten Krankheitsfälle/Unfälle
$c$	-	Anzahl der exponierten Fälle ohne Krankheit/Unfall
$C$	-	Gewichtungswert
$d$	-	Anzahl der nicht exponierten Fälle ohne Krankheit/Unfall
$d_+$	-	Kürzester Abstand zwischen der Trennebene und dem am nächsten liegenden Datensatz der Klasse +1
$d_-$	-	Kürzester Abstand zwischen der Trennebene und dem am nächsten liegenden Datensatz der Klasse -1
$E$	-	Exposition
$\bar{E}$	-	Keine Exposition
$EB_j$	-	Langsam veränderliche Eventbewertung des Events $j$
$f$	-	Faktor, Verhältnis der Unfall- zu den Nicht-Unfall-Events
$fft$	-	Diskrete Fouriertransformation
$H$	-	Hyperebene
$\mathcal{H}$	-	Höherdimensionaler Raum
$i(N)$	-	Maß für die Unreinheit ( <i>engl.</i> Impurity) der Datensätze eines Knotens $N$
$k$	-	Parameter der k-fachen Kreuzvalidierung
$K$	-	Krankheit/Unfall
$\bar{K}$	-	Keine Krankheit/Kein Unfall
$K_i$	-	Datensatzklasse $i$
$K(x_i, x_j)$	-	Kernelfunktion
$L_D$	-	Konvexe Kostenfunktion
$L_i$	-	Endknoten (oder Blätter) eines Entscheidungsbaums
$L_P$	-	Lagrange-Funktion

$m_1$	-	Anzahl der exponierten Fälle
$m_2$	-	Anzahl der nicht exponierten Fälle
$m_{try}$	-	Anzahl der an jedem Knoten verfügbaren Merkmale
$n$	-	Anzahl aller untersuchten Fälle der Vierfeldertafel
$n_1$	-	Anzahl der Krankheitsfälle/Unfälle
$n_2$	-	Anzahl der Fälle ohne Krankheit/Unfall
$n_{exponiert}$	-	Mindeststichprobengröße für exponierte Fälle
$n_{min}$	-	Mindeststichprobengröße
$n_{nicht\_exponiert}$	-	Mindeststichprobengröße für nicht exponierte Fälle
$n_{tree}$	-	Anzahl der Entscheidungsbäume des Gesamtmodells beim Random Forest
$N_i$	-	Knoten $i$ eines Entscheidungsbaums
$N_L$	-	Linker Folgeknoten eines Ausgangsknotens $N$
$N_R$	-	Rechter Folgeknoten eines Ausgangsknotens $N$
$O_1$	-	Chance für die Fälle mit Krankheit/Unfall
$O_2$	-	Chance für die Kontrollen ohne Krankheit/Unfall
$p_j(N)$	-	Relative Häufigkeit der $j$ -ten Klasse des Knotens $N$
$p_L$	-	Datensatzanteil des linken Folgeknotens $N_L$
$p_R$	-	Datensatzanteil des rechten Folgeknotens $N_R$
$P$	-	Wahrscheinlichkeit
$q$	-	Anzahl aller Merkmale
$R$	m	Kurskrümmungsradius
$R_i$	-	Pearson-Korrelationskoeffizient des $i$ -ten Merkmals
$SE[\ln(OR)]$	-	Standardabweichung des logarithmierten Odds Ratios
$v$	km/h	Fahrzeuglängsgeschwindigkeit
$Var$	-	Varianz (stochastisches Maß)
$v_{diff}$	km/h	Differenzgeschwindigkeit zum Vorderfahrzeug
$v_{Obj,abs}$	km/h	Absolute Objektgeschwindigkeit
$\mathbf{w}$	-	Normalenvektor der Hyperebene
$x_{acc,est}$	m/s <sup>2</sup>	Geschätzte Relativbeschleunigung des Objekts zum Ego in x-Richtung
$x_i$	-	Zugehöriges Merkmal am Knoten $i$ eines Entscheidungsbaums
$\mathbf{x}_i$	-	$q$ -dimensionaler Merkmalsvektor des $i$ -ten Datensatzes
$\tilde{x}_{OR}$	-	Verechnung der Odds Ratio $OR_i$ aller in einer Gruppe enthaltenen Kategorien $i$
$x_{pos}$	m	Distanz des Objekts zum Ego in x-Richtung
$x_{vel}$	m/s	Relativgeschwindigkeit des Objekts zum Ego in x-Richtung
$y_i$	-	Binäre Zielklasse des $i$ -ten Datensatzes
$y_{pos}$	m	Distanz des Objekts zum Ego in y-Richtung
$y_{vel}$	m/s	Relativgeschwindigkeit des Objekts zum Ego in y-Richtung
$Z_{1-\alpha/2}$	-	z-Quantil eines zweiseitigen $(1-\alpha)\%$ -Konfidenzintervalls

# 1 Einleitung und Motivation

Unfälle im Straßenverkehr sind überaus seltene Ereignisse. So passierte in Deutschland im Jahr 2016 durchschnittlich nur alle 296.000 Kraftfahrzeug-Kilometer ein polizeilich erfasster Unfall [1, S. 6]. Todesfälle im Straßenverkehr ereignen sich für den gleichen Zeitraum sogar nur alle 238 Mio. Kraftfahrzeug-Kilometer. Im Vergleich der letzten Jahre ist zwar eine generell abnehmende Tendenz an Getöteten im Straßenverkehr zu verzeichnen, jedoch hat sich diese Entwicklung deutlich abgeschwächt beziehungsweise führte sogar zu einer Steigerung wie in den Jahren 2014 und 2015 (Abb. 1.1). Weltweit stellten Straßenverkehrsunfälle im Jahr 2012 für den Altersbereich zwischen 15 und 29 Jahren die häufigste Todesursache dar [2, S. 1].




Abb. 1.1 Getötete im Straßenverkehr in Deutschland [3][4]

Der deutsche Verkehrssicherheitsrat beschloss 2007, die „Vision Zero“, ein Verkehrssystem ohne Schwerverletzte oder Getötete, als Ziel seiner Verkehrssicherheitsarbeit zu formulieren [5, S. 8]. Der ursprünglich propagierte Vorsatz, bereits im Jahr 2020 die „Vision Zero“ für Deutschland zu erreichen, erscheint aktuell nicht realistisch.

Ungeachtet davon steigen die Einbauraten von aktiven Fahrzeugsicherheitssystemen wie die automatische Notbremse (ANB) [6, S. 57]. Sie haben, beispielhaft für ein Notbremssystem, das Potential bis zu 43% aller Pkw-Unfälle zu vermeiden. Den stagnierenden Unfallzahlen zufolge existieren aber weiterhin Unfälle, die aktuelle Fahrerassistenzsysteme (FAS) nicht oder nur ungenügend adressieren und deshalb auch nicht verhindern können.

Dem zugrunde liegt ein ständiger Kompromiss in der Funktionsauslegung. Jede Situationsbewertung im Fahrzeug erfordert eine Entscheidung, die dementsprechend direkt zu einer Auslösung oder im weitaus häufigeren Fall zum Ausbleiben einer Auslösung führt. Besonders

in der Auslegung aktiver Sicherheitssysteme mit Eingriff vor einem Unfall muss der Zielkonflikt zwischen korrekter Entscheidung, richtig positiv (RP) sowie richtig negativ (RN), und falscher Entscheidung, falsch positiv (FP, Fehler 1. Art, Falschalarm) sowie falsch negativ (FN, Fehler 2. Art, fälschlicherweise ausbleibender Alarm), getroffen werden. Zu viele Fehlauflösungen verhindern eine hohe Wirksamkeit durch geringere Nutzerakzeptanz und führen infolgedessen zu einem Abschalten des Systems. Zu viele fälschlicherweise ausbleibende Auslösungen senken den direkten Systemnutzen.

Neben einer hohen Schätzgenauigkeit des Gefährdungspotentials ist eine möglichst frühe Vorhersage dessen anzustreben. Je eher eine valide Aussage getroffen und damit eine Fahrreaktion eingeleitet werden kann, desto mehr Handlungsspielraum zur Unfallvermeidung entsteht, wie schon ENKE [7] 1979 anhand physikalischer Zusammenhänge gezeigt hat: Eine halbe Sekunde an früherer Reaktion besitzt bereits das Potential, die Hälfte aller Querverkehrs- und Auffahrkollisionen zu vermeiden.

Vor diesem Hintergrund ermöglichen Innovationen in den Technologiebereichen der Datenanalyse und Informationstechnik einen besseren Umgang mit großen Datenmengen und daraus generierten Erkenntnissen. Das sogenannte digitale Zeitalter soll das Leben der Menschen in den kommenden Jahrzehnten ähnlich stark verändern wie die Industrielle Revolution [8, S. 35ff]. Methoden des maschinellen Lernens in Disziplinen wie der Medizin, dem Maschinenbau, der Marktforschung oder der Betriebswirtschaft gelten als kommende Innovationstreiber [9][10][11][12]. Auch in der Kurzgeschichte und dem gleichnamigen Film „Minority Report“ wird die Vorhersage von Kriminalfällen visionär dargestellt und scheitert doch am Ende aufgrund von falsch positiv Fällen [13].

## 2 Stand der Wissenschaft

Jeder Ansatz zur Untersuchung der Unfallwahrscheinlichkeit ist abhängig von den untersuchten Daten und den verwendeten Analysemethoden. Das vorliegende Kapitel gibt zuerst einen Überblick zum Stand der Wissenschaft, welche Daten von Fahrten im Straßenverkehr verfügbar sind und wie sich diese vorverarbeiten sowie bezüglich ihrer Kritikalität bewerten lassen (Kap. 2.1). Danach erfolgt eine Übersicht zur retrospektiven Bestimmung von langsam veränderlichen Einflussfaktoren auf die Unfallwahrscheinlichkeit aus Unfalldatenbanken und Studiendaten (Kap. 2.2). Abschließend werden Ansätze zur prädiktiven Schätzung der Unfallwahrscheinlichkeit aufgrund schnell veränderlicher Einflussfaktoren (Kap. 2.3) vorgestellt und damit die Voraussetzung für die Diskussion des Stands der Wissenschaft im darauffolgenden Kapitel 3 gegeben.

### 2.1 Daten von Fahrten im Straßenverkehr

Aufgezeichnete Daten von Fahrten im Straßenverkehr stellen die Voraussetzung einer Untersuchung zum Übergang von einer Normalfahrt zu einer Unfallfahrt dar. Dieser Abschnitt gibt dazu einen Überblick, welche Datenquellen von Fahrten im Straßenverkehr verfügbar sind (Kap. 2.1.1), wie daraus relevante Szenarien extrahiert werden können (Kap. 2.1.2) und sich anschließend deren Kritikalität bewerten lässt (Kap. 2.1.3).

#### 2.1.1 Verfügbare Datenquellen

Wichtigste Voraussetzung einer Datenquelle zur Untersuchung der Kritikalität ist das Vorhandensein von Unfällen oder zumindest kritischen Situationen. Da diese, wie in Kapitel 1 bereits erwähnt, äußerst seltene Ereignisse darstellen, ergibt sich eine Anforderung bezüglich des Umfangs einer Datenquelle. Gewöhnliche, im Straßenverkehr fahrende Fahrzeuge zeichnen derzeit keine Daten zu ihrem Fahrzustand oder ihrer Umgebung aus. Eine Ausnahme bilden Fahrzeuge des Herstellers Tesla, bei denen serienmäßig Fahrzeugsignaldaten und Videoaufnahmen charakteristischer Szenarien zur Weiterentwicklung von Funktionen über eine Mobilfunkschnittstelle versendet werden können [14].

Nach ISO 26262 sind Fahrzeughersteller zur Absicherung und Erprobung sicherheitsrelevanter Funktionen verpflichtet [15]. Jede identifizierte Gefährdung durch Fehlfunktionen wird einem Sicherheitsintegritätslevel ASIL (*engl.* automotive safety integrity level) zugeordnet, das sich nach Schwere der Auswirkung, Häufigkeit der Fahrsituation und Beherrschbarkeit der Fehlfunktion bemisst. Damit einhergehend entsteht für den Hersteller ein Absicherungsumfang, der schließlich in Datenbanken von aufgezeichneten Absicherungsfahrten mündet. Zu beachten ist, dass die Daten von professionellen Testfahrern beziehungsweise von entwickelnden Ingenieuren eingefahren werden. Eine Übertragbarkeit der Informationen dieser Datenbank

auf normales Verkehrsgeschehen erscheint durch das nicht repräsentative Fahrerkollektiv eingeschränkt.

Eine weitere denkbare Datenquelle stellen Studiendaten dar. Hier werden ein oder mehrere Fahrzeuge speziell für eine Aufzeichnung von fahrzeuginternen Größen oder Umgebungsinformationen ausgerüstet. Besonders die Studientypen Naturalistische Fahrverhaltensbeobachtung (*engl.* Naturalistic Driving Study NDS) beziehungsweise Feldversuch zur Untersuchung der Wirkung von Fahrerassistenzsystemen (*engl.* Field Operational Test FOT) haben zum Ziel, ein möglichst natürliches Fahrverhalten des Fahrers aufzuzeichnen. Das Unterscheidungsmerkmal beider Klassen liegt im Studiendesign: In FOT bekommen die Probanden einen Auftrag zur Nutzung bestimmter zu untersuchender Funktionen, was bei NDS vollständig wegfällt. Das Bewusstsein des Fahrers, unter Beobachtung zu stehen, ist deshalb für FOT höher [17, S. 9]. Derartige Studien erlauben einen hohen Grad des realitätsnahen Fahrens, sind jedoch simulierten Szenarien in der experimentellen Kontrolle unterlegen (Abb. 2.1).

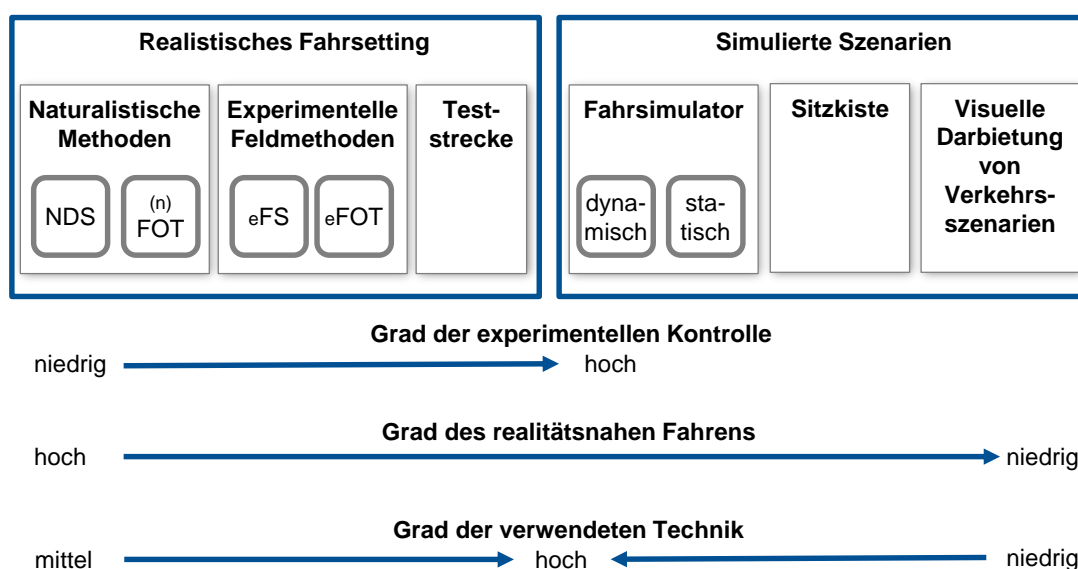


Abb. 2.1 Grad der experimentellen Kontrolle, des realitätsnahen Fahrens und der verwendeten Technik verschiedener Forschungsparadigmen im Überblick nach [16]

Unfälle sind wegen ihrer Seltenheit nur in Studien ausreichender Größe enthalten. Folglich gibt oftmals der finanzielle Aufwand ein Limit für das kostspielige Studiendesign vor und damit, wie viele Unfälle aufgezeichnet werden können.

Die größte bisher in Europa durchgeführte Studie euroFOT hatte bei 34,9 Mio. aufgezeichneten Kilometern keine beziehungsweise nur wenige Unfälle zu verzeichnen [17, S. 74][18, S. 7]. Deswegen bezogen sich alle Auswertungen auf Beinaheunfälle und Störfälle (*engl.* Incidents). Die größten, weltweit durchgeführten NDS, die 100-car-study und das Strategic Highway Research Program 2 (SHRP2), enthalten 69 beziehungsweise 1465 aufgezeichnete Unfälle [19, S. xxxv][20].

Für eine detaillierte Aufzählung von durchgeführten Fahrverhaltensstudien sei auf [16, S. 24ff] verwiesen.

## 2.1.2 Extraktion relevanter Szenarien

Von allen aufgezeichneten Rohdaten stellen relevante Szenarien oftmals nur einen Bruchteil dessen dar. Deshalb müssen über Extraktionsverfahren die für den jeweiligen Anwendungsfall charakteristischen Szenarien identifiziert werden. Es sind mehrere Vorgehensweisen zur Extraktion von Unfällen beziehungsweise kritischen Situationen bekannt: Eine Auswertung der aufgezeichneten Signale kann über Signalschwellwerte automatisiert erfolgen. Dieses Vorgehen wurde in der euroFOT Studie für verschiedene Kategorien wie Zeitlücke (*engl.* Time Head Way THW), Kollisionszeit zum Vorderfahrzeug (*engl.* Time To Collision TTC) oder über geschwindigkeitsabhängige Längsbeschleunigungsgrenzen angewandt [21, S. 7-9] [22, S. 823-825]. Daraus ergibt sich schließlich eine diskrete Einordnung in drei Gefahrenstufen, die von leicht überschrittenen Grenzwerten bis hin zur akuten Kollisionsgefahr reichen. Die anfangs hohe Rate von Fehldetektionen kritischer Situationen konnte durch die iterative Anpassung der Grenzwerte sowie die Berücksichtigung einer Fahrerreaktion gesenkt werden [22, S. 826]. Die absolute Anzahl an erkannten kritischen Ereignissen reduzierte sich folglich auch.

Im Patent von BRINKMANN [23] werden die relevanten Szenarien automatisiert in einem Analyseserver extrahiert. Als Eingangsdaten dienen Fahrzeugkinematiksignale, Video- oder andere Umgebungssensoren. Die Patentbeschreibung beinhaltet jedoch lediglich grobe Prinzipien und keine Funktionsweise oder einen Wirkungsnachweis. Über einen Crowd Sensing Ansatz lassen sich aus Bildern der vorderen Fahrzeugumgebung Kontextinformationen zur vorliegenden Verkehrssituation, was am Beispiel von Unfallhäufungspunkten gezeigt wurde, ergänzen [24]. Ein weiterer Ansatz zur automatisierten Szenariensextraktion von großen Studiendaten mit Hilfe von Petrinetzen [25] stellt sich als rechenaufwändig heraus [22, S. 821] und wurde letztendlich mit einem Verfahren fester Signalgrenzen kombiniert [21].

Die Analyse von Auffahrunfällen und Beinahe-Auffahrunfällen einer NDS zeigt, dass die Entwicklung von rein quantitativen Beinahe-Unfall-Kriterien ohne die Verifizierung durch einen menschlichen Analysten nicht möglich ist [19, S. xxiv]. Die Hauptursache dafür sei, dass sich die fahrdynamischen Größen nicht von denen in gewöhnlichen Situationen unterscheiden.

Ebenso existieren kombinierte Formen, die zuerst automatisiert Szenarienkandidaten extrahieren, um sie später manuell zu verifizieren. Solch ein Vorgehen wurde in den beiden NDS 100-car-study sowie SHRP2 angewandt [19, S. 345][26]. Einer automatisiert generierten Vorauswahl folgte eine verfeinerte Einordnung und Situationsbeschreibung anhand der Videodaten. Die Studie SHRP2 nutzte fünf Wege, um relevante, kritische Szenarienkandidaten herauszufinden [26, S. 7-8]:

- Nachträgliche Meldung durch Probanden
- Automatische Unfalldetektion im Fahrzeug durch das Datenaufzeichnungsmodul
- Manuelle Auslösung der Störfalltaste im Fahrzeug durch den Probanden
- Zufällige Entdeckung durch Analysten
- Triggerauslösung durch Grenzwertüberschreitung in der retrospektiven Datenanalyse

Anschließend folgte immer eine videobasierte manuelle Verifizierung. Einen Überblick dieser Szenariensextraktion gibt Abb. 2.2. Eine ausführliche Bewertung hinsichtlich der Leistungsfähigkeit der in SHRP2 verwendeten kinematischen Grenzwerte zur Klassifikation der Sequenzen in verschiedene Kritikalitätsstufen liefert [27].

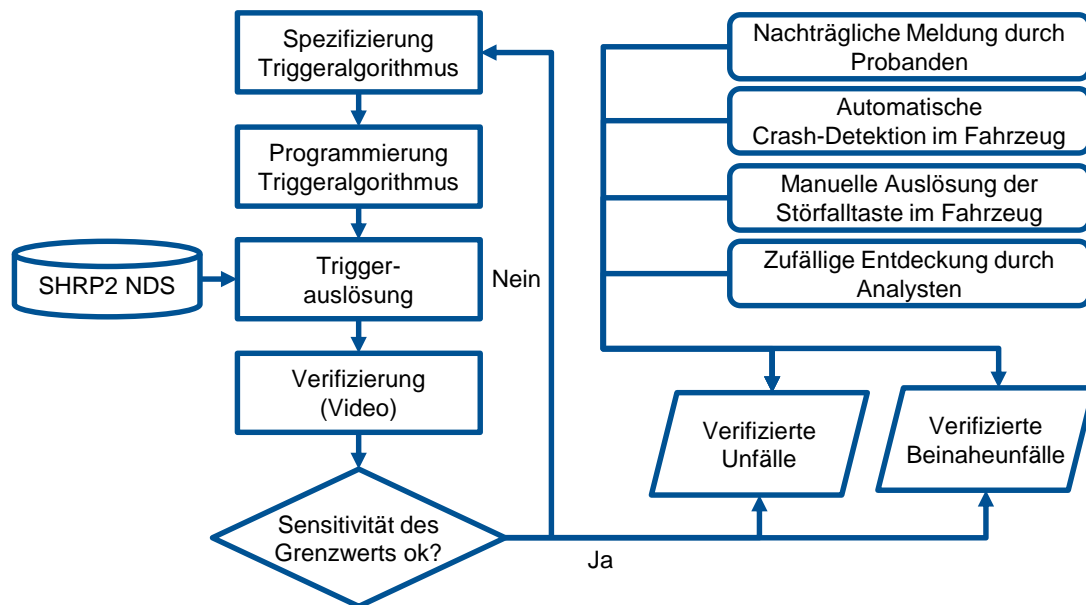


Abb. 2.2 Szenariextraktion in SHRP2 nach Hankey [26, S. 21]

Zur automatisierten Extraktion relevanter Szenarien werden Signalgrenzwerte benötigt. Diese verwenden Fahrzustandsinformationen zur Longitudinal- und Lateraldynamik sowie Umgebungsinformationen wie den Abstand zum Vorderfahrzeug. Neben einfachen Signalgrenzwerten kommen auch häufig Kombinationen davon zum Einsatz. Einen Überblick über verschiedene Störfallkriterien zur Extraktion relevanter Szenarien mehrerer Studien zeigt Tabelle 2.1.

Eine komplexere Form der Datenextraktion beschreibt EBNER [28], bei der aus Unfalldaten, NDS-Daten und Experimenten zum Fahrerverhalten Referenzszenarien identifiziert werden. Die Häufigkeit dieser Szenarien wird anschließend als Basis zur Entwicklung und Evaluation von aktiven Sicherheitssystemen verwendet.



Tabelle 2.1 Überblick über Störfallkriterien in verschiedenen Studien (teilweise nach [17, S. 80])

Studie	Longitudinal	Lateral	Abstand / Sonstiges
Wiegand et al. (2009) [29, S. 13] und Olson et al. (2010) [30, S. 20] (beide für Lkw)	$(a_x < -3,4 \frac{m}{s^2}) \&\&$ $(v > 24 \frac{km}{h})$		$(TTC \leq 1,8 s) \&\&$ $(Abstand < 45 m) \&\&$ $(v > 8 \frac{km}{h}) \&\& (\dot{\psi} \leq 4 \frac{grad}{s})$
Dingus et al. (2006) [19]	$ a_x  \geq 5,8 \frac{m}{s^2}$	$ a_y  \geq 6,9 \frac{m}{s^2}$  $(\dot{\psi} \leq 4 \frac{grad}{s})$	$(TTC \leq 4,0 s) \&\&$ $( a_x  \geq 4,9 \frac{m}{s^2})$  $(a_x \in [-4,9 \frac{m}{s^2}, -3,9 \frac{m}{s^2}]) \&\&$ $(TTC \leq 4,0 s) \&\&$ $(Abstand \leq 30,5 m)$
McGehee et al. (2007) [31]	$ a_x  \geq 4,9 \frac{m}{s^2}$	$ a_y  \geq 5,3 \frac{m}{s^2}$	
Benmimoun, Fahrenkrog, Zlocki, & Eckstein (2011) [21]	Untere Schwelle: <ul style="list-style-type: none"> <li>• <math>(a_x &lt; -6 \frac{m}{s^2}) \&amp;\&amp;</math></li> <li>• <math>(v &lt; 50 \frac{km}{h})</math></li> <li>• <math>(a_x &lt; -4 \frac{m}{s^2}) \&amp;\&amp;</math></li> <li>• <math>(v &gt; 150 \frac{km}{h})</math></li> <li>• <math>(a_x &lt; (2 \frac{m}{s^2} (v - 50 \frac{km}{h}) / 100 \frac{km}{h} - 6 \frac{m}{s^2})) \&amp;\&amp;</math></li> <li>• <math>(v \in [50 \frac{km}{h}, 150 \frac{km}{h}])</math></li> </ul>	Untere Schwelle: <ul style="list-style-type: none"> <li>• <math>( a_y  \geq 4 \frac{m}{s^2}) \&amp;\&amp;</math></li> <li>• <math>(v &gt; 100 \frac{km}{h})</math></li> <li>• für <math>(v &lt; 100 \frac{km}{h})</math>: Grenzwerte <math>a_y \in [2,5 \frac{m}{s^2}, 7 \frac{m}{s^2}]</math> in Abhängigkeit von <math>v</math></li> </ul>	$(TTC \leq 1,75 s)$
	Obere Schwelle: $a_x < -8 \frac{m}{s^2}$	Obere Schwelle: <ul style="list-style-type: none"> <li>• <math>( a_y  \geq 9 \frac{m}{s^2}) \&amp;\&amp;</math></li> <li>• <math>(v &lt; 50 \frac{km}{h})</math></li> <li>• <math> a_y  \geq 8 \frac{m}{s^2} \&amp;\&amp;</math></li> <li>• <math>(v &gt; 50 \frac{km}{h})</math></li> </ul>	$(THW < 0,5 s) \&\&$ $(v_{diff} > 20 \frac{km}{h})$
		Schwellwerte der Gierrate: $( \dot{\psi}  \geq 15 \frac{grad}{s})$ bis $( \dot{\psi}  \geq 50 \frac{grad}{s})$	$(THW < 0,35 s)$
Hankey et al. SHRP2-Report (2016) [26, S. 10]	<ul style="list-style-type: none"> <li>• <math>a_x &lt; -6,4 \frac{m}{s^2}</math>, auf Autobahnen:</li> <li>• <math>a_x &lt; -2,9 \frac{m}{s^2}</math></li> <li>• <math>a_x \leq -9,81 \frac{m}{s^2}</math></li> <li>• <math>a_x \geq 4,9 \frac{m}{s^2}</math></li> </ul>	<ul style="list-style-type: none"> <li>• <math> a_y  \geq 7,4 \frac{m}{s^2}</math></li> <li>• <math> \dot{\psi}  \geq 15 \frac{grad}{s^2}</math></li> <li>• <math> \dot{\psi}  \geq 8 \frac{grad}{s}</math></li> <li>• <math>( a_y  \geq 9,81 \frac{m}{s^3}) \&amp;\&amp;</math></li> <li>• <math>(v &gt; 18 \frac{km}{h})</math></li> </ul>	Systemeingriffe von Fahrzeugsicherheitssystemen (ABS, ASR, ESP, Airbag)

### 2.1.3 Bemessung der Kritikalität

Die Kritikalität ist eine Größe, um die Bedrohung oder die Gefahr einer Verkehrssituation zu beschreiben [32]. Äquivalent zum Begriff Kritikalität wird in der Literatur häufig der Ausdruck Risiko zur Beurteilung von Verkehrssituationen verwendet. Die ISO 31000 definiert Risiko als

„Auswirkungen von Unsicherheit auf Ziele“ und berechnet es als Kombination aus Eintrittswahrscheinlichkeit und Schadensausmaß [33]. Im Rahmen dieser Arbeit bezeichnet Kritikalität ein kontinuierliches Maß für die Wahrscheinlichkeit eines Unfalls. Die Schwere des möglichen Schadens ist darin nicht berücksichtigt. Es gilt zu beachten, dass ein Kritikalitätsmaß nicht zwingend der mathematischen Definition einer Wahrscheinlichkeit inklusive des Wertebereichs von 0 bis 1 genügen muss. Die Unfallwahrscheinlichkeit ist damit eine Teilmenge aller Kritikalitätsmaße. Für die Kritikalität existieren sowohl objektive als auch subjektive Maße.

Objektive Kritikalitätsmaße bewerten häufig zugehörige Fahrmanöver. Beispielsweise kann für Spurwechselforgänge ein Kritikalitätskriterium angegeben werden, das sich nach den Überlappungsanteilen der prädizierten Aufenthaltsorte des Ego-Fahrzeugs und umliegenden Objekten bemisst [34].

Die Kritikalität für Auffahrunfälle kann über die Intensität von Ausweichmanövern berechnet werden [32]. Die Intensität stammt aus einer Beschleunigungsnorm, die longitudinale und laterale Beschleunigungen des Fahrzeugschwerpunkts verknüpft. Die minimal-intensive Vermeidungstrajektorie, die die Beschleunigungsnorm minimiert, stellt hier eine quantitative Bewertung der Kritikalität dar.

Über Geschwindigkeitsverläufe lässt sich in einer makroskopischeren Sichtweise ebenso eine Kritikalität beurteilen [35]. In diesem Fall werden kinematische Wellen in der Nähe von Nadelöhen auf Autobahnen ausgewertet. Das Kritikalitätsmaß für Auffahrunfälle setzt sich hierbei aus einer Verrechnung der Größen Verkehrsdichte, Straßenauslastung, durchschnittliche Fahrzeuglänge und durchschnittliche Fahrzeuggeschwindigkeit zusammen.

Ein kontinuierliches Kritikalitätsmaß kann basierend auf der Distanz zum nächsten Objekt berechnet werden [36]. Dabei generalisiert das vorgestellte Maß zeitbezogene Maße wie die TTC oder die Zeit, um zu reagieren (*engl.* Time To React, TTR). Es ist ebenso möglich über eine Looming-TTC (*engl.* drohend) eine Schnittpunktberechnung von Trajektorien mit Unsicherheiten durchzuführen und daraus eine kontinuierliche Unfallwahrscheinlichkeit abzuleiten [37].

Subjektive Maße versuchen eine Kritikalität anhand der menschlichen Empfindung einer Bedrohung oder Gefahr abzubilden. So werden in [38] Fahrten eines Lkw-Simulators durch Experten evaluiert, die auf einer diskreten Skala von 0 bis 100 jeden Zeitschritt bewerten. Ein ähnlicher Ansatz bewertet in [39] Pre-Crash-Szenarien eines Fahrsimulators. Hierbei wird das subjektive Kritikalitätsempfinden des Fahrers mit objektiven Maßen wie einer minimalen Ausweichbeschleunigung oder einer maximalen Gierrate verglichen. Die Situationsbewertung hängt jedoch stark vom Fahrer und dem Evaluationszeitpunkt ab und lässt sich daher nur schwer modellieren. Das Einbeziehen weiterer messbarer Fahrerinformationen wie Fahrstil, Müdigkeit oder Situationsbewusstsein wird für künftige Forschungsarbeiten zur Verbesserung der Ergebnisse empfohlen.

## **2.2 Retrospektive Bestimmung langsam veränderlicher Einflussfaktoren auf die Unfallwahrscheinlichkeit**

Langsam veränderliche Einflussfaktoren auf die Unfallwahrscheinlichkeit stellen Umstände dar, die sich für gewöhnlich kaum oder nur langsam während einer Fahrt verändern. Dazu gehören

Attribute wie die Tageszeit, Wetterbedingungen, Nebentätigkeiten des Fahrers oder Straßeneigenschaften. Häufig liegen diese in der Literatur oder in aufgezeichneten Daten von Fahrten im Straßenverkehr in kategorialer Form für bestimmte Zeiträume vor. Denkbare Zeitspannen, in denen diese Attribute bestehen, erstrecken sich von mehreren Sekunden (z.B. Nebentätigkeiten des Fahrers) bis hin zu Stunden (z.B. Wetterbedingungen). Bis auf Zeitreihendaten (Kap. 2.3) beinhalten damit langsam veränderliche Einflussfaktoren alle Umstände, die sich auf die Unfallwahrscheinlichkeit auswirken.

## **2.2.1 Langsam veränderliche Einflussfaktoren aus Unfalldatenbanken**

Es existieren in der Literatur viele Ansätze zur Bestimmung von langsam veränderlichen Einflussfaktoren in Unfalldatenbanken (Tabelle 2.2). Die Bestimmung der Unfallwahrscheinlichkeit beziehungsweise Unfallhäufigkeit meint hier die Schätzung von Unfalldaten und weist keinen direkten Bezug zu einer Unfallprädiktion im Fahrzeug wie in Kapitel 5 auf. Die retrospektive Analyse und Modellierung von Zusammenhängen in Unfalldaten ermittelt stets Unfallhäufigkeiten oder Unfallschweren unter der Bedingung, dass überhaupt ein Unfall vorliegt. Alle vorgestellten Ansätze folgen dem Prinzip, dass die langsam veränderlichen Einflussfaktoren als Variablen in einen Schätzprozess einbezogen werden. Als Untersuchungsziel können zum einen Größen wie eine Unfallhäufigkeit oder Unfallschwere bestimmt werden. Eine weitere Möglichkeit ist die Ermittlung von Unfallbegleitumständen für bestimmte Teilmengen von Unfällen wie beispielsweise tödlichen Unfällen. Letztendlich resultiert die Untersuchung der Einflussfaktoren dieser Verfahren in der Bestimmung von Häufigkeiten, Modelleinflussparametern oder Risikogrößen. Der Fokus des Abschnitts liegt in der Vorstellung der Einflussfaktoren, auf die verwendeten Methoden wird in Kap. 2.2.3 genauer eingegangen.

Die Umgebung wurde als häufigste Kategorie zur Bestimmung von langsam veränderlichen Einflussfaktoren aus Unfalldatenbanken herangezogen. So konnte mit dem Einfluss der Straßenoberfläche eine Unfallschwere in Unfalldatenbanken geschätzt werden [40][41][42][43][44]. Im Gegensatz dazu waren die Untersuchungen zum Straßentyp meist das Resultat von Klassifikations- und Odds Ratio Analysen hinsichtlich der Unfallbegleitumstände [45][46][47][48]. Das Odds Ratio ist ein statistisches Maß für die Stärke eines Zusammenhangs [49, S. 120] und wird im Abschnitt 2.2.3 ausführlicher erklärt. Die Informationen zum Straßenverlauf wie Steigung, Gefälle oder Krümmung wurden zur Erstellung von Schätzmodellen zur Unfallhäufigkeit [40][50][51] und Unfallschwere [40][41][42][44] eingesetzt. Wohl aufgrund der guten Verfügbarkeit in Unfalldatenbanken ist der Einfluss der Licht- und Wetterverhältnisse Ergebnis von vielen Analysen.



Der Unfallzeitpunkt in Form von Tageszeit oder Wochentag kann zum einen zur Schätzung der Unfallschwere [40][42][44] verwendet werden. Zum anderen diente die Tageszeit, der Wochentag sowie die Jahreszeit in Odds Ratio Analysen zur Quantifizierung der Auswirkung auf die Häufigkeit für tödliche Unfälle [47][48][54]. Der zum Unfallzeitpunkt vorliegende Verkehr wurde in makroskopischeren Untersuchungen hinsichtlich des Verkehrsflusses, der Standardabweichung der gefahrenen Geschwindigkeiten und der Verkehrsstärke einbezogen [40][41][56][58][59]. Einflussfaktoren aus der Kategorie Fahrzeug wurden in Machine Learning Ansätzen als Prädiktoren [43][44] einer Unfallschwere eingesetzt oder bei der Untersuchung von Unfallbegleitumständen in den Analyseprozess integriert [45][46][54][55]. Demografische Informationen des Fahrers wie Alter und Geschlecht sind in vielen Unfalldatenbanken verfügbar. Sie finden deshalb in allen Bereichen Anwendung. Häufig untersucht ist der Zusammenhang zwischen tödlichen Unfällen und den vorliegenden Umständen wie dem Fahreralter [47][48][52][54]. Weiter verwendete Bezugsgrößen sind die Unfallhistorie und Verkehrsdelikte des Fahrers [47][50][57]. Einen großen Anteil nehmen Einflussfaktoren ein, die den Fahrer in seiner Fahraufgabe einschränken. Oft wird der Alkohol- oder Drogenkonsum mit einer hohen Unfallschwere in Verbindung gebracht [42][43][47][53].

Analysen, die den Fahrer- und Fahrzeugzustand zum Unfallzeitpunkt betreffen, sind aufgrund der retrospektiven Datenaufnahme weniger in Unfalldatenbanken als vielmehr in Studiendaten (Kap. 2.2.2) zu finden. Diese Informationen lassen sich durch nachträgliche Fahrerbefragungen sowie Unfallrekonstruktion erheben. Damit kann die Aufmerksamkeit, Ablenkung oder Müdigkeit des Fahrers in den Schätzprozess integriert werden [48][50][53][55]. In wenigen Fällen sind überdies die gefahrene Geschwindigkeit oder der Abstand zum Vorderfahrzeug vor einem Unfall in den Schätzprozess miteinbezogen [53][55].

## 2.2.2 Langsam veränderliche Einflussfaktoren aus Studiendaten

Das Studiendesign von NDS oder FOT eignet sich grundsätzlich, um Einflussfaktoren auf die Unfallwahrscheinlichkeit während einer Normalfahrt zu bestimmen. Im Gegensatz zu Unfalldaten sind hier auch aufgezeichnete Normalfahrten (Baselinedaten) vorhanden. Nur durch die Gegenüberstellung von nichtkritischen Daten und Unfallsequenzen ist es möglich, eine prädiktive Aussage zur Unfallwahrscheinlichkeit zu treffen. Das aufwändige Studiendesign lässt damit die Untersuchung von Nebentätigkeiten des Fahrers zu, was aus reinen Unfalldatenbanken derart nicht möglich wäre.

Die erste größere NDS, die 100-car naturalistic driving study, erlaubte die Quantifizierung des Einflusses vieler Fahrerhandlungen. Eine Bewertung von Nebenaufgaben, gruppiert nach drei Komplexitätslevel, zeigt Tabelle 2.3 [60].

Tabelle 2.3 Quantifizierung von Nebenaufgaben des Fahrers nach [60]

Komplexitätslevel	Beispiele für Nebentätigkeiten	Odds Ratio
Komplex	Lesen, Smartphone bedienen, Greifen nach bewegtem Objekt	3,1
Moderat	Essen, Telefonieren, Greifen nach statischem Objekt	2,1
Einfach	Trinken, Rauchen, Singen, Radio einstellen	1,2

Die bisher größte in Europa durchgeführte Studie EuroFOT untersuchte die Aufmerksamkeit des Fahrers, seine Nebentätigkeiten oder das Auftreten kritischer Situationen während der Nutzung von Fahrerassistenzsystemen (FAS) wie Abstandsregeltempomat (*engl.* Adaptive

Cruise Control ACC), Geschwindigkeitsbegrenzer (*engl.* Speed Limiter SL), Tempomat, Frontkollisionswarner oder Spurhalteassistent (*engl.* Heading Control HC) [61].

Über einen manöverbasierten Ansatz wurden in [17] Zusammenhänge zwischen Nebentätigkeiten wie dem Telefonieren und der Wahrscheinlichkeit für kritische Situationen in EuroFOT untersucht. Entgegen der Ergebnisse der 100-car Studie in [60] verringert sich das Störfallrisiko während des Telefonierens im Vergleich zu einer Normalfahrt ohne Telefonieren [17, S. 95]. Dieses Resultat deckt sich mit einer für Lastkraftwagen und Bussen durchgeführten NDS, die ebenso für das Telefonieren ein Odds Ratio nahe 1 herausfand und damit einen negativen Einfluss nicht statistisch signifikant nachweisen konnte [30, S. 44][62, S. xii]. Eine aktive Beteiligung am Telefongespräch ergab in der SHRP2 NDS sogar eine signifikante Verringerung der Wahrscheinlichkeit für Beinahe-Unfälle [63, S. 102]. Der in dieser Untersuchung gewählte Ansatz einer Cross-over Studie vergleicht in zwei Sequenzen den gleichen Fahrer, was die nutzbare Fallanzahl senkt. Dadurch konnte für Unfälle aufgrund fehlender Fälle keine Aussage getroffen werden.

Die Fahrerunaufmerksamkeit stellte sich auch in einer Häufigkeitsuntersuchung einer NDS mit Daten aus den USA und Afrika als wichtigster Unfallauslöser für Auffahrunfälle heraus [64]. Eine kombinierte Analyse von Fahrerverhalten und Fahreralter einer NDS zeigt, dass von jungen Fahrern verursachte Auffahrunfälle, die durch Smartphone-Nutzung beeinflusst wurden, in den Jahren 2007 bis 2015 gestiegen sind [65, S. 15]. Eine Quantifizierung unter Verwendung von Baseline-Daten fand nicht statt.

Die in SHRP2 enthaltenen Variablen Fahrerbeeinträchtigung, Fahrerleistung, Fahrfehler und Fahrerablenkung wurden über eine Odds Ratio Analyse in ihre unterschiedlichen Unterkategorien quantifiziert [66, S. 2639]. Tabelle 2.4 zeigt zusammenfassend die Ergebnisse der übergeordneten Variablen sowie deren zugehörige Unterkategorien.

Tabelle 2.4 Quantifizierung von Fahrerbeeinträchtigung, Fahrerleistung, Fahrfehler und Fahrerablenkung nach [66, S. 2639]

Untersuchte Variable	Zugehörige Unterkategorien	Odds Ratio
Fahrerbeeinträchtigung	Drogen/Alkohol, Müdigkeit, Emotion (Zorn, Traurigkeit, Weinen und/oder andere emotionale Agitation)	5,2
Fahrfehler	Offensichtliche Unerfahrenheit mit dem Fahrzeug/Straßenumgebung, Toter-Winkel-Fehler, unerlaubtes Wenden, Vorfahrtsverstoß, Ampelverstoß, Geisterfahren, zu langsames Fahren, plötzliches oder unangemessenes Bremsen/Anhalten, unterlassenes Fahrtrichtungsanzeigen	18,2
Fahrerleistung	Aggressives Fahren (generell beobachtetes Verhalten), Rasen (Geschwindigkeitsübertretung, unangemessene Geschwindigkeit), Unsicheres Rasen in Gewerbegebiet, illegales/unsicheres Überholen, Verstoß Sicherheitsabstand, absichtliches Unterlassen der Fahrtrichtungsanzeige, absichtlicher Stoppschild-/Vorfahrtsschild-Verstoß	11,1
Fahrerablenkung	Bedienung des verbauten Radios / Klimaanlage / sonstigen verbauten Geräten, Smartphone-Nutzung (surfen, wählen, greifen, schreiben, telefonieren), Kind auf dem Rücksitz, Interaktion mit erwachsenem/jugendlichem Mitfahrer, Lesen/Schreiben (inklusive Tablets), Essen, Trinken (nicht-alkoholisch), persönliche Hygiene, Greifen nach einem Objekt (nicht Smartphone), im Sitz zur Musik tanzen, verlängerte Blickabwendung auf externes Objekt	2,0

Die Fahrerleistung und das Fahrerverhalten während widriger Wetterbedingungen kann mit einem Regressionsmodell auf einem beschränkten Datensatz von SHRP2 abgebildet werden [67, S. 12]. Wegen fehlender Unfall- oder Beinahe-Unfall-Daten ist jedoch keine Quantifizierung hinsichtlich der Unfallwahrscheinlichkeit möglich.

Neben dem Fahrerverhalten konnten aus der 100-car NDS auch die Einflüsse der Umgebung wie Lichtbedingung, Straßenoberflächenzustand oder Verkehrsfluss zur Unterscheidung zwischen Unfällen, Beinahe-Unfällen und Störfällen quantifiziert werden [68, S. 55]. Daten von Normalfahrten wurden nicht in das logistische Regressionsmodell einbezogen. Dadurch sind diese Ergebnisse, trotz der Verwendung von Studiendaten, nicht zur Bestimmung der Einflussfaktoren auf die Unfallwahrscheinlichkeit während einer Normalfahrt geeignet.

Mit Wetterinformation angereicherte SHRP2 Straßeninformationsdaten aus den Bundesstaaten Florida und Washington wurden verwendet, um die Auswirkung von schlechten Sichtbedingungen auf die Unfallwahrscheinlichkeit zu quantifizieren [69]. Neben einer gestiegenen Unfallwahrscheinlichkeit bei schlechten Sichtbedingungen ließen sich als zusätzliche Schlüsselfaktoren für Unfälle junge und alte Fahrer, Straßen mit niedrigem Reibwert, Straßen mit höherer zulässiger Geschwindigkeitsbegrenzung, Kurven, ungeteilte Fahrbahn, Vorhandensein einer Lichtsignalanlage und keine Beleuchtung während Dunkelheit identifizieren.

Für Abkommensunfälle auf Straßen außerorts konnten aus Teilen der SHRP2 Studie Zusammenhänge zwischen den Kurvenradien, der gefahrenen Geschwindigkeit, dem Verlauf der Querablagen, der Fahrzeit, dem Zeitpunkt der Fahrerreaktion, dem Fahreralter und Ablenkungen des Fahrers hergeleitet werden [70]. Methodisch stellt diese Mischung aus langsam und einigen schnell veränderlichen Einflussfaktoren eine interessante Kombination dar. Zum Zeitpunkt der Auswertung standen lediglich ein Unfall und drei Beinahe-Unfälle aus den Studiendaten zur Verfügung. Zur Kompensation wurden Ersatz-„Unfallszenarien“ auf Basis der Querablage und Querbeschleunigung definiert. Aus diesem Grund sind die Ergebnisse nur bedingt nutzbar.

Die Klassifikation von Sequenzen aus SHRP2 in fünf Stufen wie Unfall, Beinahe-Unfall und drei verschiedenen kritischen Baseline-Fällen ist mit Hilfe einer multinomialen logistischen Regression möglich [71]. Aus dem Fahrerverhalten und den Umgebungsdaten wurden dazu die einflussreichsten Kategorien identifiziert und daraus Merkmale für die Schätzmodelle gebildet. Neben der Klassifikation konnten für die Variablen Fahrerverhalten und Nebentätigkeiten die einflussreichsten Kategorien ermittelt werden.

### **2.2.3 Methoden zur retrospektiven Bestimmung von Einflussfaktoren**

Dieser Abschnitt widmet sich den Methoden zur retrospektiven Bestimmung von langsam veränderlichen Einflussfaktoren aus den Abschnitten 2.2.1 und 2.2.2. Generell lassen sich die Modellierungsmethoden zur Untersuchung von Unfallhäufungsdaten nach LORD [72] aufteilen in:

- Parametrierung von statistischen Verteilungen (z. B. Poisson-, negative Binomial- oder Conway-Maxwell-Poisson-Verteilung)
- Parametrierung von Funktionen (z. B. Regressionsmodelle)
- Kombination genannter Beispiele (in multivariaten und/oder hierarchischen Modellen)

- Maschinelles Lernen (z. B. Künstliches Neuronales Netz, Bayes'sches Künstliches Neuronales Netz, Support Vector Machine)

Für eine detaillierte Beschreibung und Diskussion der Modellierungsmethoden sei auf [72] verwiesen.

Neben einer vollständigen Modellierung von Zusammenhängen aus Unfalldaten hat sich zur Quantifizierung von Einflussfaktoren auf die Unfallwahrscheinlichkeit aus Studiendaten ein Ansatz aus der Medizin bewährt. Eine Odds Ratio Analyse untersucht, wie stark das Auftreten einer Krankheit mit der An- beziehungsweise Abwesenheit bestimmter Bedingungen korreliert. In retrospektiven Studien des Typs Fall-Kontroll-Studie, dem auch eine NDS angehört, wird als Assoziationsmaß das Odds Ratio verwendet [73, S. 34]. Es werden dabei die Anzahlen aller exponierten Fälle mit den nicht-exponierten verglichen. Daraus ergibt sich für jeden Vergleich eine Vierfeldertafel (Tabelle 2.5).

Tabelle 2.5 Vierfeldertafel zur Bestimmung des Assoziationsmaßes Odds Ratio

		Exposition		$\Sigma$
		Exposition ( $E$ )	Keine Exposition ( $\bar{E}$ )	
Krankheit	Krankheit ( $K$ )	a	b	$n_1$
	Keine Krankheit ( $\bar{K}$ )	c	d	$n_2$
$\Sigma$		$m_1$	$m_2$	$n$

Für eine Fall-Kontroll-Studie ist die gemessene Variable die Exposition eines Falls. Das Odds Ratio wird durch das Verhältnis der Chancen (*engl.* odds) zueinander gebildet [74, S. 73]. Die Chance  $O_1$  für die Fälle und die Chance  $O_2$  für die Kontrollen berechnen sich zu

$$O_1 = \frac{P(E|K)}{P(\bar{E}|K)} \text{ und } O_2 = \frac{P(E|\bar{K})}{P(\bar{E}|\bar{K})}, \quad (2.1)$$

wobei zum Beispiel  $P(E|K)$  die Wahrscheinlichkeit einer Exposition unter allen Fällen mit Krankheit darstellt.

Das Odds Ratio  $OR$  einer Fall-Kontroll-Studie ergibt folglich [74, S. 73]:

$$OR = \frac{O_1}{O_2} = [P(E|K)/P(\bar{E}|K)]/[P(E|\bar{K})/P(\bar{E}|\bar{K})]. \quad (2.2)$$

Jedoch liegen im Allgemeinen die Studienergebnisse ohne bedingte Wahrscheinlichkeiten vor. Deshalb wird das Odds Ratio  $OR$  mit den absoluten Häufigkeiten aus Tabelle 2.5 angenähert [74, S. 73]:

$$OR = [(a/n_1)/(b/n_1)]/[(c/n_2)/(d/n_2)] = ad/bc. \quad (2.3)$$

Wenn der Anteil der Krankheitsfälle im Vergleich zu den Fällen ohne Krankheit klein ist, stellt das Odds Ratio auch eine Approximation des Relativen Risikos  $RR$  dar [74, S. 73][75, S. 657]:

$$RR = (a/m_1)/(b/m_2) = (\dots) = OR [(b/d) + 1]/[(a/c) + 1]. \quad (2.4)$$

Das Odds Ratio hat gegenüber dem Relativen Risiko den analytischen Vorteil, dass es nicht auf das Intervall zwischen 0 und 1 beschränkt ist, sondern von 0 bis  $\infty$  reicht [63, S. 42]. Der



Odds Ratio Ansatz wird in Kapitel 4 zur Quantifizierung von langsam veränderlichen Einflussfaktoren auf die Unfallwahrscheinlichkeit aus Studiendaten verwendet.

## 2.3 Prädiktive Schätzung der Unfallwahrscheinlichkeit aufgrund schnell veränderlicher Einflussfaktoren

Schnell veränderliche Einflussfaktoren stellen Zustände des Gesamtsystems aus Fahrer, Fahrzeug und Umwelt dar, die sich während einer Fahrt zeitlich schnell verändern. Beispiele hierfür sind Signale aus der Fahrdynamik oder der Umgebungssensorik. In dieser Arbeit beziehen sich schnell veränderliche Einflussfaktoren immer auf aufgezeichnete Zeitreihendaten. Typische Zeiträume, in denen diese Zustände bestehen, liegen meist unter 10 s und sind zudem nach unten durch die vorliegende Abtastfrequenz beschränkt. Je früher und genauer eine Prädiktion von schnell veränderlichen Einflussfaktoren erfolgen kann, desto mehr Potential ergibt sich für aktive Fahrzeugsicherheitssysteme zur Unfallvermeidung.

Wie in 2.1.3 bereits erwähnt, ist die Kritikalität eine Größe, um die Bedrohung oder die Gefahr einer Verkehrssituation zu beschreiben [32]. Eine erste Möglichkeit, eine objektive Unfallwahrscheinlichkeit zu präzisieren, ist die Klassifikation in diskrete Kritikalitätsstufen. Diese sind oftmals direkt in den verwendeten Studiendaten gegeben [76][77][78] oder lassen sich über selbst definierte Signalschwellen bestimmen [79]. Oft werden auch kontinuierliche Kritikalitätsmaße (vgl. 2.1.3) präzisiert [32][36][80]. Neben objektiven Maßen existieren zudem Konzepte, die eine subjektive Kritikalität präzisieren [38]. Tabelle 2.6 gibt eine Übersicht zur prädiktiven Schätzung objektiver und subjektiver Kritikalität.

Tabelle 2.6 Literaturübersicht zur prädiktiven Schätzung objektiver und subjektiver Kritikalität

Quelle	Input	Methode	Ergebnis der Prädiktion
[76][77]	Längsbeschleunigungswerte aus SHRP2 Sequenzen	Diskrete Fourier-Transformation, K-Means Clusterverfahren	Klassifikation von Sequenzen
[79]	Beinahe-Unfälle	Entscheidungsbäume	Klassifikation von Sequenzen in Kritikalitätsstufen
[32]	Brems- und Ausweichmanöver	Random Forest Klassifikation mit Merkmalsselektierung	Kritikalitätsstufen
[36][80]	Szenarien aus Simulationen	Prädiktive Risikokarte	Pfadplanung für kognitive Fahrzeuge
[37]	Künstliche generierte Trajektorienpaare	Support Vector Machine	Unfallwahrscheinlichkeit
[35][81]	Echtzeitdaten von Induktionsschleifen auf Autobahnen	Logistische Regression	Unfallwahrscheinlichkeit
[82]	Echtzeitdaten von Induktionsschleifen auf Autobahnen	Support Vector Machine	Unfallwahrscheinlichkeit
[38]	Aufgezeichnete Fahrten aus Lkw-Fahrsimulator	Entscheidungsbäume, SVM, K-Nearest Neighbor Klassifikation, Künstliche Neuronale Netze	Klassifikation in subjektive Kritikalitätsstufen aus Expertenevaluation

Ein K-Means Clusterverfahren kann rein aus Längsbeschleunigungswerten von SHRP2 Sequenzen die Kritikalitätsstufe der gesamten Fahrsequenz schätzen [76][77]. Der in der

Literatur häufig verwendete Begriff der Prädiktion ist hier genau genommen eine reine Schätzung. Den verwendeten Schätzmodellen wurde der vollständige Signalverlauf bis über den Ereigniszeitpunkt hinaus übergeben. Eine Aussage für künftige Zeitschritte ist damit nicht möglich. Ein ähnlicher Ansatz klassifiziert rein auf Längsszenarien beschränkte SHRP2 Sequenzen [78]. Es fand ebenso keine Beschränkung der genutzten Signale auf den Zeitraum vor einem potentiellen Unfall statt.

[79] führt eine Schätzung der Kritikalitätsstufe an Beinahe-Unfällen mit Hilfe von Entscheidungsbäumen durch. Die Wahl der Methode ermöglicht zudem die Auflistung der für den Klassifikationsprozess wichtigsten Merkmale: Geschwindigkeit während Bremsung, Ampelschaltung, Objekttyp und potentieller Unfalltyp. Die 912 als Beinahe-Unfälle bezeichneten Fahrsituationen stammen aus einer Studie mit 8500 Fahrzeugkilometern, was etwa alle 10 km einem Beinahe-Unfall entspräche. Die häufige Deklaration einer Fahrsituation als Beinahe-Unfall begründet sich in der Verwendung von deutlich niedrigeren Auslösebedingungen wie bei vergleichbaren Studien (Kap. 2.1.2).

Ein Random Forest Klassifikationsmodell mit Merkmalsauswahl kann die Kritikalität von kombinierten Brems-/Ausweichmanövern zwischen dem Ego-Fahrzeug und einem weiteren Fahrzeug vor einem potentiellen Unfall präzisieren [32]. Die Beurteilung mit dem aus einem überwachten Lernprozess erstellten Modell soll weniger Rechenaufwand als die Fahrdynamiksimulation vieler Konstellationen benötigen. Dadurch lassen sich die Echtzeitanforderungen aktiver Fahrzeugsicherheitssysteme leichter erreichen. Ein ähnlicher Ansatz plant sichere Trajektorien in komplexen, dynamischen Szenarien [83]. Die Prädiktion und Sicherheitsbewertung von Beschleunigungs- und Lenkradwinkelprofilen ist über ein dreidimensionales, faltendes neuronales Netz (*engl.* 3D Convolutional Neural Network: ConvNet) umgesetzt.

EGGERT und DAMEROW [36][80] spannen unter Berücksichtigung der Fahrdynamik die möglichen, erreichbaren Zustandskombinationen zweier Fahrzeuge für einige Beispielszenarien auf und führen damit eine kontinuierliche Kritikalitätsschätzung auf Basis von Kollisionswahrscheinlichkeiten durch. Das Ergebnis in Form von prädiktiven Risikokarten kann wiederum zur Pfadplanung von kognitiven Fahrzeugen verwendet werden.

Ein ähnlicher Ansatz nutzt zufällig generierte, künstliche Trajektorienpaare zweier Fahrzeugmodelle [37]. Daraus wird die Kritikalität mit dem kontinuierlichen Maß Looming TTC bestimmt. Die errechneten Werte werden einer SVM mit radialer Kernel-Basisfunktion als Merkmale übergeben. Das angelernte Modell prädiziert die Kollisionswahrscheinlichkeit für einen Zeithorizont von 2 s. Die gezeigten Ergebnisse neigen zu einem empfindlichen Verhalten für Fehlprädiktionen in engen Konstellationen.

Aus Echtzeitdaten von Induktionsschleifen auf Autobahnen lässt sich ebenso eine Unfallwahrscheinlichkeit präzisieren. Es kann zum einen eine Unfallwahrscheinlichkeit mit Hilfe einer logistischen Regression bestimmt [35][81], zum anderen ein Hierarchisches Bayes'sches Probitmodell zur Unfallschwereschätzung verwendet werden. Die wichtigen Merkmale stammen aus statistischen Kennzahlen von Geschwindigkeitsprofilen (Durchschnitt, Standardabweichung), der Straßenauslastung oder Wettereinflüssen. Diesen Ansätzen liegt ein makroskopischer Ansatz zugrunde, weil gleichzeitig die Daten vieler Fahrzeuge einbezogen werden. Eine prädiktive Schätzung mit fahrzeuginternen Größen ist damit nicht möglich.

Anstatt objektive Kritikalitätsmaße zu schätzen, kann auch die subjektive, von Experten wahrgenommene Kritikalität, als Zielgröße für die Schätzmethode dienen [38]. Aus den Fahrdaten eines Lkw-Simulators führten drei Experten eine kontinuierliche Kritikalitätsbeurteilung auf einer Skala von 0 bis 100 durch, die anschließend in fünf Kritikalitätsstufen weiter diskretisiert

wurden. Die verwendeten Merkmale stammen aus der Fahrdynamik, der Umgebung sowie vom Fahrer. Mit den Methoden Entscheidungsbaum, SVM, k-Nearest Neighbor Klassifikation und Künstliche Neuronale Netze konnte die Kritikalität mit ausreichender Güte klassifiziert werden. Obwohl das Vorgehen keine Prädiktion darstellt, würde sich dieser Ansatz mit einem Zeitversatz zwischen Merkmalsgrößen und Kritikalität direkt für eine Prädiktion eignen.

Eine Klassifikation von Sequenzen in Kritikalitätsstufen von den Studiendaten aus der 100-car study beziehungsweise SHRP2 kann mittels der langsam veränderlichen Einflussfaktoren aus dem Fahrerverhalten und den Umgebungsdaten erfolgen [68][71]. Weil keine schnell veränderlichen Einflussfaktoren in die Schätzung mit verschiedenen Formen der logistischen Regression miteinbezogen werden, sind die Ansätze nicht in der Tabelle aufgeführt. Die Auswertungen nutzen immer bereits alle langsam veränderlichen Eventvariablen ohne Beschränkungen im Zeithorizont und sind demzufolge auch keine wirkliche zeitliche Prädiktion.

Die prädiktive Schätzung einer Unfallwahrscheinlichkeit kann auch immer einem modularen Ansatz folgen. Dazu werden getrennt voneinander zwei verschiedene Schritte durchlaufen: Zuerst wird die Fahrzeugbewegung prädiziert. Diese kann mit einem Ansatz zur Fahrmanövervorhersage [84][85], der Aufstellung aller physikalisch möglichen Trajektorien [86], der Simulation mit einem Einspur-Fahrzeugmodell zur Pfadprädiktion [87] oder mit einer Prädiktion ganzer Verkehrsszenen [88][89] erfolgen. Für einen detaillierteren Überblick zur Bewegungsprädiktion von Fahrzeugen sei auf [90, S. 2-9] verwiesen. Anschließend wird in einem zweiten Schritt die prädizierte Fahrzeugkonstellation bewertet. Die in Kap. 2.1.3 gezeigten Kritikalitätsmaße lassen sich nun direkt anwenden und ergeben somit auch eine prädiktive Schätzung der Unfallwahrscheinlichkeit.



# 3 Diskussion des Stands der Wissenschaft und Idee der Arbeit

Der in Kapitel 2 dargestellte Stand der Wissenschaft soll nun kritisch unter Ableitung von Forschungsfragen diskutiert werden (Kap. 3.1). Davon leitet sich die Idee und der Aufbau der vorliegenden Arbeit ab (Kap. 3.2.)

## 3.1 Diskussion des Stands der Wissenschaft und Ableitung von Forschungsfragen

### Zielkonflikt zwischen Datentiefe und Fallanzahl

#### Kritik:

Die Anzahl der enthaltenen Fälle eines Datensatzes beeinflusst die Anwendbarkeit, Generalisierbarkeit und Aussagekraft der daraus generierten Aussagen. Deshalb wird häufig aufgrund des sehr seltenen Auftretens von Unfällen auf Beinahe-Unfälle, die dann auch zum Teil mit niedrigen Auslöseschwellen ausgewählt wurden, zurückgegriffen [70][79]. Des Weiteren ist der Nachweis, dass eine Häufung von Beinahe-Unfällen auch eine Häufung von Unfällen nach sich zieht, wegen fehlender Unfälle oftmals nicht prüfbar [17, S. 75]. Vor diesem Hintergrund stellt die Studiengröße mit einer ausreichenden Anzahl an Unfällen ein wichtiges Kriterium dar, das in der Literatur bisher kaum beachtet wurde. Datenbasen mit enthaltenen Unfällen bei gleichzeitiger Aufzeichnung von Fahrzeugzeitreihendaten sind wegen des großen Aufwands selten (Kap. 2.1.1).

#### Forschungsfrage 1:

Kann der Zielkonflikt aus Datentiefe und Fallanzahl durch die Nutzung einer großen NDS aufgelöst werden?

### Validierung der Schätzung eines kontinuierlichen Kritikalitätsmaßes

#### Kritik:

Die Schätzung einer kontinuierlichen Kritikalität ist nicht validierbar. Erst das Auftreten eines Unfalls bestätigt wirklich die Kritikalität. Alle diskreten oder kontinuierlichen Zwischenstufen (Kap. 2.1.2 und 2.1.3) können immer unter der vollen Kontrolle des Fahrers (beziehungsweise des Systems) und dessen Fahrerwunsch stattfinden. Damit ist die Nutzung von Szenarien aus Beinahe-Unfällen als Zwischenstufe als nicht zielführend anzusehen. Eine proportionale Abhängigkeit der Häufigkeit von Beinahe-Unfall- und Unfallszenarien ist bisher nicht eindeutig zu

beweisen. Einerseits wird von einer grundsätzlichen Eignung, aber einem Unterschätzen der unfallbeeinflussenden Faktoren bei Verwendung von Beinahe-Unfällen- und Unfällen, gesprochen [91]. Andererseits zeigen sich aber auch tiefgreifende Unterschiede zwischen Beinahe-Unfällen und Unfällen am Beispiel Auffahrunfall [92].

Die Unfallschwere ist ebenso bezüglich der Kritikalität zu betrachten. So werden in der Datenbank SHRP2 Bordsteinüberfahrten als „minor Crashes“ den Unfällen zugeordnet [20]. Diese überschreiten zwar bestimmte definierte Auslöseschwellen zur Detektion von Unfällen (Kap. 2.1.2), stellen aber keinerlei Gefährdung für die Fahrzeuginsassen dar. Sie sind deshalb nicht als kritisch anzusehen. Objektive Kritikalitätsmaße adressieren zudem meist spezielle Manöver oder Szenarien [32][34] und sind daher weniger für die Anwendung vieler verschiedener Szenarien geeignet.

#### **Forschungsfrage 2:**

Kann durch ausschließliche Nutzung und Vergleich von unkritischen Fahrsequenzen (genannt Baseline) mit Unfallsequenzen einer angemessenen Unfallschwere das Validierdilemma umgangen werden?

## **Nutzung von langsam veränderlichen Einflussfaktoren und dynamischen Fahrzeugsignalen zur prädiktiven Schätzung einer Kritikalität**

#### **Kritik:**

Prädiktive Schätzmethode der Unfallwahrscheinlichkeit nutzen keine langsam veränderlichen Einflüsse (Kap. 2.2 und 2.3). Die Analyseverfahren zur prädiktiven Schätzung einer Unfallwahrscheinlichkeit beschränken sich rein auf Fahrzeugdaten [32][36][79][80][92], auf verkehrstechnische Ansätze ohne direkten Bezug zum Einzelfahrzeug [35][41][81][82] oder versuchen ausschließlich, mit langsam veränderlichen Einflussfaktoren eine Aussage zu generieren [71].

#### **Forschungsfrage 3:**

Lassen sich langsam veränderliche Einflussfaktoren für eine bessere Schätzgüte der Kritikalität in den Prädiktionsprozess integrieren?

## **Nutzung des Erfahrungswertes von aufgezeichneten Unfallsequenzen zur Prädiktion der Kritikalität**

#### **Kritik:**

Analysen von Unfalldaten ohne Informationen zu nichtkritischen Fahrten besitzen eine begrenzte Aussagekraft. Alle in Abschnitt 2.2.1 vorgestellten Ansätze zur Bestimmung langsam veränderlicher Einflussfaktoren basieren rein auf Unfalldaten. Für Aussagen zum Übergang einer unkritischen in eine Unfallsituation sind Baseline-Daten notwendig, die in Unfalldaten naturgemäß nicht vorhanden sind. Nur über zusätzliche, parallel generierte Baseline-Daten wären solche Aussagen möglich [93].

Unfalldaten inklusive zugehöriger Baseline-Daten enthalten aufgrund vieler Beispiele einen Erfahrungswert an positiven und negativen Fällen. Das ähnelt in gewisser Weise der Vorgehensweise eines menschlichen Fahrers, der nur sehr wenige Unfälle verursacht. Diesem

stehen zwar nicht viele Lernbeispiele zur Verfügung, er schafft es aber durch Vorstellungskraft, daraus eine Vielzahl möglicher Variationen zu erzeugen. Dies verbessert wiederum seine Entscheidungen in ähnlichen Situationen. Genau diese abstrakte Vorstellungskraft ist nicht gut durch ein maschinelles Verfahren abbildbar. Eine Maschine erkennt nur Zusammenhänge, wenn genug positive und negative Lernbeispiele vorhanden sind. Bisher werden aber diese Lernbeispiele einer Unfalldatenbank inklusive zugehöriger Baseline-Daten nicht zur Unfallvorhersage verwendet (Kap. 2.3).

#### **Forschungsfrage 4:**

Lässt sich durch Maschinenlernverfahren retrospektiv der „Erfahrungswert“ aus Sequenzen einer Unfalldatenbank inklusive zugehöriger Baseline-Daten zur Unfallprädiktion nutzen?

### **Untersuchung des Zusammenhangs eines hinreichend weiten Prädiktionszeitraums und der Güte der Kritikalitätsschätzung sowie der Wichtigkeit von Einflussfaktoren**

#### **Kritik:**

Einige Untersuchungen beschränken sich im prädiktiven Schätzprozess nicht zeitlich und sind deshalb genau genommen keine Prädiktionen, sondern reine Bewertungen [76][77][79]. Die Prädiktion der Kritikalität von HERRMANN [32] oder WARD [37] für mögliche Konstellationen zweier Fahrzeuge erstreckt sich nur über wenige Sekunden (2s bzw. 2,5s) und gibt keine Auswertung zur Wichtigkeit von Einflussfaktoren. Es bleibt daher offen, wie sich die Güte der Kritikalitätsprädiktion in unterschiedlich weiten Zeiträumen verhält. Außerdem fehlt die Information, welche Einflussfaktoren für die Schätzung in den jeweiligen Zeiträumen als relevant eingestuft werden.

#### **Forschungsfragen 5, 6 und 7:**

Lässt sich ein Zusammenhang zwischen der erreichbaren Kritikalitätsschätzungsgüte und der Prädiktionszeit für hinreichend weite Zeiträume herleiten?

Kann man zuverlässig 3 s bis 5 s vor einem Unfall diesen erkennen und den Fahrer warnen?

Kann die Wichtigkeit der Einflussfaktoren einer Kritikalitätsschätzung für unterschiedliche Prädiktionszeiträume bestimmt werden?

## **3.2 Aufbau und Idee der Arbeit**

Aus den entwickelten Forschungsfragen soll nun die Idee der Arbeit abgeleitet werden. Die Auseinandersetzung mit den Forschungsfragen 1 und 2 erfolgt kapitelübergreifend. Durch die Nutzung der bisher größten durchgeführten NDS SHRP2 mildert sich der Zielkonflikt zwischen Datentiefe und Fallanzahl aus Forschungsfrage 1 ab: Insgesamt enthält die Studie Datensequenzen aus 80 Mio. Fahrzeugkilometern [26]. Aufgrund der Aufzeichnung von sowohl Fahrdynamik- als auch Umgebungsdaten ist eine hohe Datentiefe gegeben (Kap. 4.1). Neben einer Vielzahl von unkritischen Fällen sind insgesamt 845 Unfälle ausreichender Unfallschwere enthalten (Kap. 4.2). Die Validierungsthematik in Forschungsfrage 2 wird ebenfalls durch die Beschränkung der verwendeten Daten auf nichtkritische Baseline-Fälle zusammen mit Unfällen ausreichender Unfallschwere adressiert.

In Abschnitt 2.2 wurden retrospektiv langsam veränderliche Einflussfaktoren auf die Unfallwahrscheinlichkeit vorgestellt. Für eine möglichst gute Kritikalitätsvorhersage müssen diese in geeigneter Form in einen prädiktiven Schätzprozess integriert werden, was bisher im Stand der Wissenschaft nicht geschieht (Forschungsfrage 4). Deshalb identifiziert und quantifiziert Kapitel 4 langsam veränderliche Einflussfaktoren auf die Unfallwahrscheinlichkeit. Die in der Literatur vorhandenen Einflussfaktoren aus Unfalldaten dienen hierbei als Orientierung (Kap. 2.2.1). Da mit den Ergebnissen die Bewertung einer Normalfahrt möglich sein soll, können auch nur Fahrdaten aus einem Studientyp wie einer NDS und keine reinen Unfalldaten verwendet werden (Kap. 2.2.2). Als Methode zur retrospektiven Bestimmung langsam veränderlicher Einflussfaktoren wird die Odds Ratio Analyse herangezogen. Diese hat sich in der Literatur für die Auswertung von NDS-Daten bewährt (Kap. 2.2.3). Dazu wird der verwendete Datensatz beschrieben (Kap. 4.1) und vorverarbeitet (Kap. 4.2) sowie das Vorgehen einer Odds Ratio Analyse dargelegt (Kap. 4.3). Anknüpfend stellt Abschnitt 4.4 die Ergebnisse in den Kategorien Umwelteinfluss, Fahrerezustand und Fahrmanöver dar und diskutiert selbige (Kap. 4.5).

Anschließend werden in Kapitel 5 diese Ergebnisse in den Prädiktionsprozess integriert (Forschungsfrage 3). Kapitel 5 hat zum Ziel, Klassifikationsmodelle für eine prädiktive Kritikalitätsschätzung mit maschinellem Lernen zu erstellen und auszuwerten. Die Modelle sollen aus Beispielsequenzen der Studie lernen und an unbekanntem Sequenzen auf ihre Schätzgüte untersucht werden (Forschungsfrage 5). Hierfür werden Zeitreihendaten aus SHRP2 verwendet (Kap. 5.1). Aus den Zeitreihendaten und den langsam veränderlichen Kritikalitätsmaßen aus Kapitel 4 werden Merkmale erzeugt (Kap. 5.3.3) und daraus die relevanten ermittelt (Kap. 5.3.4). Die in Abschnitt 5.3.1 ausgewählten Methoden maschinellen Lernens erzeugen daraus prädiktive Klassifikationsmodelle. Wertet man diese mit den Eingangsdaten aus, lassen sich Zusammenhänge zwischen dem gewählten Prädiktionszeitraum, der zugehörigen Wichtigkeit von Merkmalen und der erreichten Schätzgüte darstellen (Forschungsfragen 5, 6 und 7). Diese Erkenntnisse werden im Ergebnis- und Diskussionsteil 5.4 gezeigt und diskutiert.

In Kapitel 6 folgt eine allgemeine Diskussion sowie ein Ausblick, Kapitel 7 fasst die Arbeit zusammen. Abb. 3.1 zeigt die Struktur und den Aufbau der Arbeit.



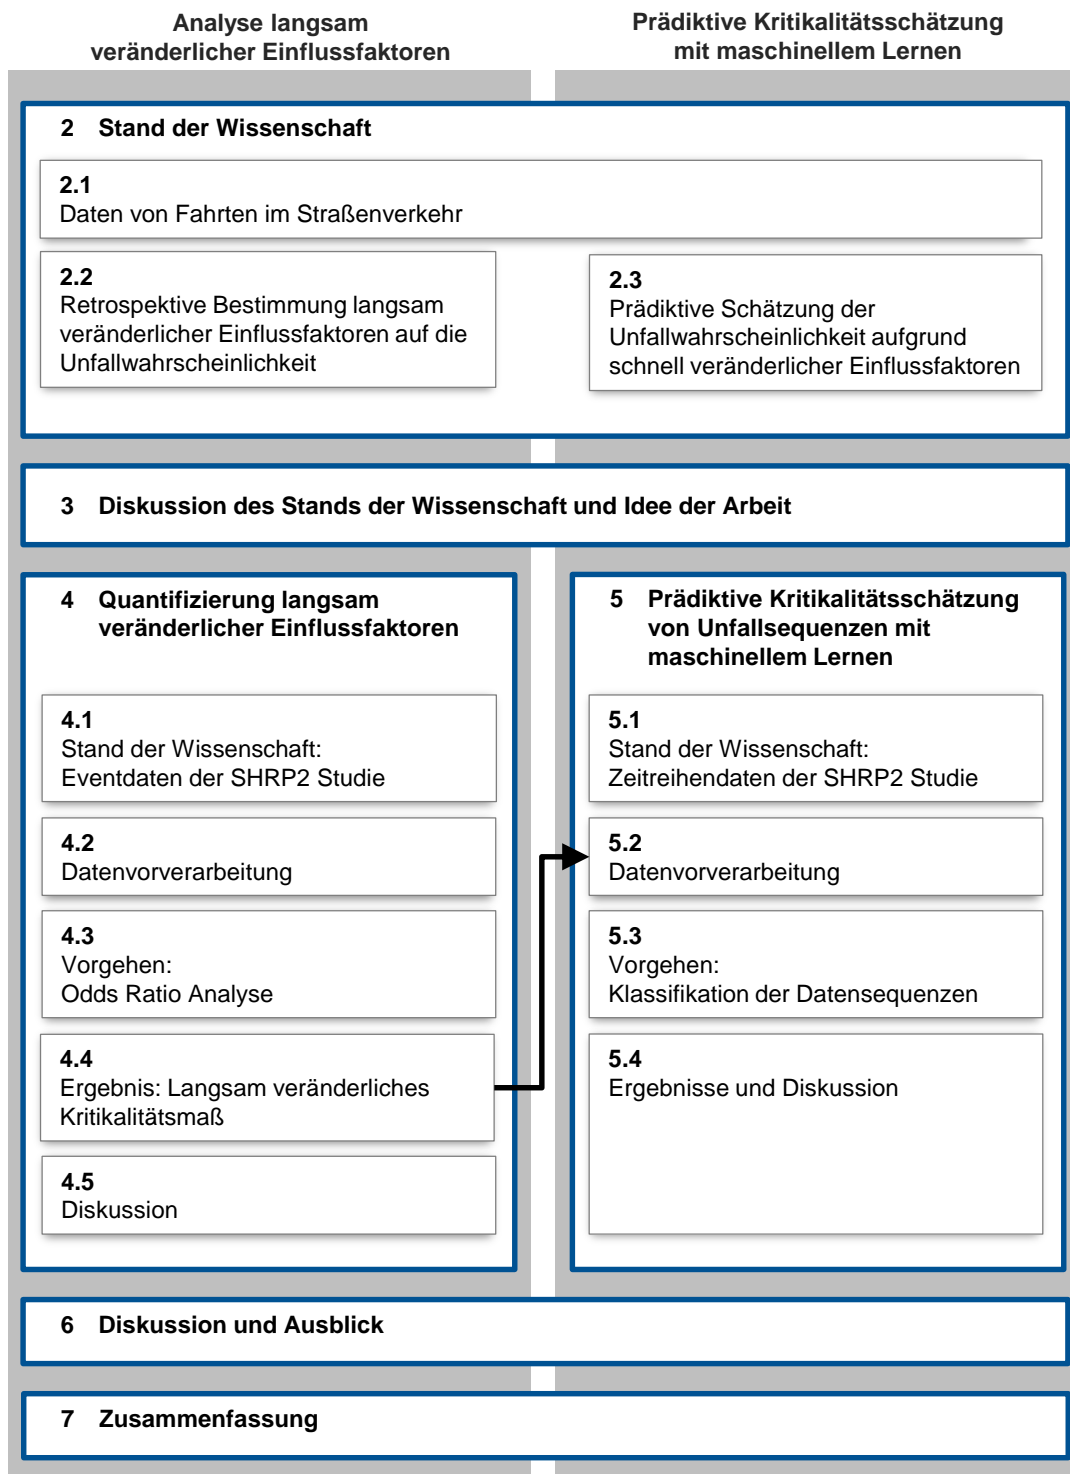


Abb. 3.1 Überblick zum Aufbau der Arbeit



# 4 Quantifizierung langsam veränderlicher Einflussfaktoren

Das folgende Kapitel beschreibt die Quantifizierung langsam veränderlicher Einflussfaktoren auf die Unfallwahrscheinlichkeit. Dazu wird zuerst der verwendete Datensatz vorgestellt (Kap. 4.1), eine Variablenauswahl getroffen (Kap. 4.2) und das Vorgehen der Odds Ratio Analyse (Kap. 4.3) dargelegt. Es folgt die Vorstellung der gewonnenen Ergebnisse (Kap. 4.4) sowie eine Diskussion derer (Kap. 4.5).

## 4.1 Stand der Wissenschaft: Eventdaten der SHRP2 Studie

Die verwendeten Daten [95] stammen aus der naturalistischen Fahrverhaltensstudie (*engl.* Naturalistic Driving Study NDS) Strategic Highway Research Program 2 (SHRP2) [26]. Diese fand in den USA zwischen 2006 und 2015 statt und ist die bisher größte derartig durchgeführte Untersuchung [26, S. 15]. Insgesamt nahmen 3.247 Probanden aller Alters- und Bevölkerungsschichten teil und fuhren ca. 80 Millionen Fahrzeugkilometer auf 6,6 Millionen Fahrten ein. Als Fahrzeuge wurden die privaten Fahrzeuge der Probanden verwendet und mit einem Datenaufzeichnungssystem ausgerüstet (Abb. 4.1).




Abb. 4.1 Schematischer Aufbau des Datenaufzeichnungssystems in Fahrzeugen der SHRP2 Studie [94]

Insgesamt führte die Extraktion relevanter Szenarien (Kap. 2.1.2) zur Identifikation von 1.465 Unfällen und 2.710 Beinahe-Unfällen. Dabei sind alle Unfälle in Unfallschwerestufen eingeteilt, die sich von Bordsteinremplern über leichte Unfälle bis hin zu polizeilich meldepflichtigen und schweren Unfällen erstrecken. Im verwendeten Datensatz sind zudem noch 20.000 nichtkritische Sequenzen (Baselines) vorhanden. Die Baseline-Fälle stammen aus 32.586 zufällig

ausgewählten Fahrsequenzen [26, S. 33]. Ungefähr 2/3 davon wurden von den beteiligten Forschern zu einem ausgewogenen Baseline-Datensatz (*engl.* balanced-sample Baseline) von 20.000 Fällen zusammengestellt. Diese Auswahl soll eine ausgewogene Repräsentation des normalen Fahrens aller Fahrer der gesamten SHRP2 Studie darstellen [26, S. 33]. Die Definition von Baseline-Events legt fest, dass die Geschwindigkeit nicht länger als zwei aufeinanderfolgende Sekunden unter 8km/h fallen darf [96, S. 43]. Eine mögliche verzerrte Darstellung von Eventkategorien im Niedriggeschwindigkeitsbereich wie Parken oder Staufahrt wird im Rahmen dieser Arbeit akzeptiert.

Eine detaillierte Beschreibung zugehöriger Zeitreihendaten erfolgt in Abschnitt 5.1. Hier wird zuerst auf die Eventdaten der Studie eingegangen. Jeder Datensatz enthält von geschultem Personal auf Basis einer Videoanalyse beschriebene, zusätzliche Informationen zum Fahrevent, zum Fahrer und zur Umgebung [26, S. 16]. Diese sogenannten Eventdaten bestehen neben einigen charakteristischen Zeitpunkten meist aus kategorialen Variablen in Textform. Als Beispiele seien das Wetter oder die Nebentätigkeiten des Fahrers genannt. Alle in der Studie enthaltenen Variablen der Eventdaten sind in Tabelle 4.1 dargestellt. Ein detaillierte Beschreibung zur Anleitung des geschulten Personals sowie eine Definition aller möglichen Unterkategorien der Eventvariablen zeigt [96].

Tabelle 4.1 Überblick aller Eventdaten jedes Datensatzes in SHRP2 [96, S. 11ff.]

<b>Fahreventvariablen</b>	<b>Fahrervariablen</b>	<b>Umgebungsvariablen</b>
Startzeit Auslöseevent in ms	Fahrer-ID	Einflussnahme auf das Event
Zeitpunkt Fahrerreaktion in ms	Fahrerverhalten (1-3)	<ul style="list-style-type: none"> <li>durch das Fahrzeug</li> <li>durch die Infrastruktur</li> <li>durch Sichtbehinderung</li> <li>durch die Kreuzung</li> </ul>
Zeitpunkt Aufprall/kritischster Moment in ms	Fahrerbeeinträchtigungen	Lichtverhältnisse
Endzeitpunkt Event in ms	Anzahl der Passagiere	Wetter
Pre-Incident Manöver	<ul style="list-style-type: none"> <li>auf Vordersitzen</li> <li>auf Rücksitzen</li> </ul>	Straßenoberflächenzustand
Bewertung Pre-Incident Manöver	Nebentätigkeiten (1-3)	Gestaltung Verkehrsweg
Auslösendes Fahrevent	<ul style="list-style-type: none"> <li>Art der Nebentätigkeiten</li> <li>Startzeitpunkt in ms</li> <li>Endzeitpunkt in ms</li> <li>Einflussnahme auf das Event</li> </ul>	Anzahl erreichbarer Fahrstreifen
Rolle im Unfall Fahrzeug 1 (Ego)	Hände am Lenkrad	Anzahl Fahrstreifen in eigener Fahrtrichtung
Rolle im Unfall Fahrzeug (2-3)	Nutzung des Sicherheitsgurtes	Fahrstreifennummer von Fahrzeug 1 (Ego)
Eventbeschreibung (1-2)		Verkehrsdichte
<ul style="list-style-type: none"> <li>Eventstart</li> <li>Unfall-/Störfalltyp</li> <li>Unfallschwere</li> <li>Fahrerreaktion oder Ausweichmanöver</li> <li>Post-Manöver</li> </ul>		Verkehrsregelung
Airbagauslösung		Kreuzungsnähe
Fahrzeugüberschlag		Straßenkrümmung
Eventbeschreibung in Berichtform		Straßensteigung
		Umgebungsbeschreibung
		Baustellennähe
		Anzahl aller beteiligten Verkehrsteilnehmer
		Anzahl an beteiligten Objekten/Tieren
		Verursacher des Events
		Verkehrsteilnehmer (2-3)
		<ul style="list-style-type: none"> <li>Ort</li> <li>Typ</li> <li>Pre-Incident Manöver</li> <li>Ausweichmanöver</li> </ul>

## 4.2 Datenvorverarbeitung

Einige zuvor vorgestellte Variablen enthalten Informationen, die nur nach vollständiger Video-durchsicht der Sequenzen verfügbar sind. Für eine Prädiktion im Fahrzeug können nur solche verwendet werden, die auch vor dem Unfall im Fahrzeug vorliegen. Außerdem werden nur kategoriale Variablen weiterverwendet. Tabelle 4.2 zeigt die Auswahl der im Folgenden weiter genutzten Variablen sowie deren vorgenommene Einteilung in die Bereiche Umwelt sowie Fahrerezustand und Fahrmanöver.

Tabelle 4.2 Auswahl der im Fahrzeug vor dem Unfall vorliegenden Variablen

<b>Umwelt</b>	<b>Fahrerezustand und Fahrmanöver</b>
Lichtverhältnisse	Anzahl der Passagiere auf Vordersitzen
Wetterverhältnisse	Anzahl der Passagiere auf Rücksitzen
Straßenoberflächenzustand	Nutzung des Sicherheitsgurtes
Gestaltung Verkehrsweg	Nebentätigkeiten
Anzahl erreichbarer Fahrstreifen	Fahrerbeeinträchtigungen
Anzahl Fahrstreifen in eigener Fahrtrichtung	Hände am Lenkrad
Verkehrsdichte	Pre-Incident Manöver
Verkehrsregelung	
Kreuzungsnähe	
Straßenkrümmung	
Straßensteigung	
Umgebungsbeschreibung	
Baustellennähe	

Wie aus der Diskussion des Stands der Wissenschaft in Abschnitt 3.1 hergeleitet, sollen entweder nur unkritische Fälle (Baseline) oder Unfälle mit einer angemessenen Unfallschwere in die weitere Analyse einfließen. Deshalb reduziert sich die Datenbasis durch Weglassen der geringsten Unfallschwerestufe, die vor allem Bordsteinrempler umfasst, auf die Verteilungen in Tabelle 4.3.

Tabelle 4.3 Auswahl der weiter verwendeten Fälle aufgrund der Unfallschwere

<b>Unfallschwere</b>	<b>Anzahl</b>
Schwere Unfälle	98
Polizeilich meldepflichtige Unfälle	150
Leichte Unfälle	597
Baseline-Fälle	20.000

Aus den Unfallschwerestufen „Schwere Unfälle“, „Polizeilich meldepflichtige Unfälle“ und „Leichte Unfälle“ ergeben sich damit insgesamt 845 Unfälle, denen 20.000 Baseline-Fälle gegenüberstehen. Eine detaillierte Beschreibung zur Einordnung der Unfallschwere gibt [96, S. 43].

## 4.3 Vorgehen: Odds Ratio Analyse

Dieser Abschnitt beschreibt das Vorgehen zur Berechnung der Odds Ratio aller vor einem Unfall verfügbaren Kategorien von Variablen. Dazu werden zuerst Teilmengen gebildet

(Kap. 4.3.1), um anschließend alle zugrunde liegenden Annahmen inklusive der verwendeten Berechnungen darzustellen (Kap. 4.3.2).

### 4.3.1 Bilden von Teilmengen

Die Auswirkung einer Exposition kann nur durch Vergleich eines exponierten mit einem nicht-exponierten Datensatz erfolgen. Für Variablen mit mehreren Kategorien hat das zur Folge, dass jeweils eine neutrale, nichtexponierte Kategorie festgelegt werden muss. Alle anderen Kategorien stellen bei dieser Vorgehensweise die exponierten Kategorien dar. Für den Straßenoberflächenzustand ist beispielsweise die Kategorie „trocken“ als neutrale Kategorie passend. Es zeigt sich, dass in allen verwendeten Variablen die häufigste Kategorie der Baseline-Fälle als neutrale Kategorie sinnvoll ist (Tabelle 4.4). Für Variablen ohne offensichtliche neutrale Kategorie sind infolgedessen keine Probleme im weiteren Vorgehen zu erwarten. Als Beispiel dient hierbei die Variable „Umgebungsbeschreibung“ mit der neutralen Kategorie „Gewerbegebiet“.

Tabelle 4.4 Festlegung der neutralen Kategorie für jede Variable

Verwendete Variable	Neutrale (nichtexponierte) Kategorie
Pre-Incident Manöver	Geradeausfahrt bei konstanter Geschwindigkeit
Anzahl der Passagiere auf Vordersitzen	Nur Fahrer auf Vordersitzen
Anzahl der Passagiere auf Rücksitzen	Kein Passagier auf Rücksitzen
Hände am Lenkrad	Nur linke Hand am Lenkrad
Nutzung des Sicherheitsgurtes	Sicherheitsgurt richtig angelegt
Nebentätigkeiten	Keine Nebentätigkeit des Fahrers
Fahrerbeeinträchtigungen	Keine Beeinträchtigung des Fahrers
Lichtbedingungen	Tageslicht
Wetter	Keine Beeinträchtigung durch Wetter
Straßenoberflächenzustand	Trockene Straße
Gestaltung Verkehrsweg	2 Fahrstreifen (nicht geteilt)
Anzahl erreichbarer Fahrstreifen	2 erreichbare Fahrstreifen
Anzahl Fahrstreifen in eigener Fahrtrichtung	1 Fahrstreifen in eigener Fahrtrichtung
Verkehrsdichte	Level A1: Freifahrt ohne Vorderfahrzeug
Verkehrsregelung	Keine Verkehrsregelung
Kreuzungsnähe	Keine Kreuzungsnähe
Straßenkrümmung	Gerader Straßenverlauf
Straßengefälle	Ebener Straßenverlauf
Umgebungsbeschreibung	Gewerbegebiet
Baustellennähe	Keine Baustellennähe

### 4.3.2 Annahmen und Berechnung

Das Odds Ratio beschreibt die Chance, unter Exposition einer Variable einen Unfall zu erleiden, im Vergleich zur Unfallwahrscheinlichkeit bei keiner Exposition (hier: neutrale Variable). Odds Ratio können als Multiplikatoren einer Grundkritikalität betrachtet werden. Ein Odds Ratio Faktor von zwei würde die Unfallwahrscheinlichkeit verdoppeln, verglichen mit der neutralen Kategorie. Das Vorgehen zu Annahmen und der Berechnung in diesem Abschnitt orientiert sich an [97].

Äquivalent zu Abschnitt 2.2.3 ergibt sich für jeden Vergleich einer exponierten Variable mit einer neutralen Variable eine Vierfeldertafel (Tabelle 4.5).

Tabelle 4.5 Vierfeldertafel zur Bestimmung des Assoziationsmaßes Odds Ratio für langsam veränderliche Einflussfaktoren auf die Unfallwahrscheinlichkeit

		Exposition		$\Sigma$
		Exposition ( $E$ )	Keine Exposition ( $\bar{E}$ )	
Unfall	Unfall ( $K$ )	a	b	$n_1$
	Kein Unfall ( $\bar{K}$ )	c	d	$n_2$
	$\Sigma$	$m_1$	$m_2$	$n$

Die Berechnung von Konfidenzintervallen für das Odds Ratio wird äquivalent zum Vorgehen in [74, S. 74ff] durchgeführt. Wegen des Wertebereichs des Odds Ratios von 0 bis  $\infty$  und dem Wert 1 für keinen Risikozusammenhang folgt eine nach rechts stark ausgeprägte, schiefe Stichprobenverteilung, die statistische Berechnungen erschwert. Die gebräuchlichste Lösung dieser Problemstellung transformiert die Verteilung mit Hilfe des natürlichen Logarithmus und macht sie damit besser handhabbar. Die Bestimmung von Konfidenzintervallen mit der transformierten Verteilung kann nun mit gewöhnlichen Methoden erfolgen. Anschließend wird der Wertebereich durch die Exponentialfunktion wieder auf die ursprüngliche Skala zurücktransformiert. Das symmetrische Konfidenzintervall des logarithmierten Odds Ratios resultiert schließlich für das normale Odds Ratio in einem nichtsymmetrischen Intervall (Abb. 4.2).




Abb. 4.2 Logarithmiertes Odds Ratio nach [74, S. 75]

Das Konfidenzintervall für das logarithmierte Odds Ratio nach HEDDERICH UND SACHS [75, S. 662] und LEMESHOW [74, S. 18] ergibt sich zu:

$$\ln(OR) - z_{1-\alpha/2} SE[\ln(OR)] \leq \ln(OR) \leq \ln(OR) + z_{1-\alpha/2} SE[\ln(OR)]. \quad (4.1)$$

Hierbei steht  $z_{1-\alpha/2}$  für das z-Quantil eines zweiseitigen  $(1-\alpha)\%$ -Konfidenzintervalls. Die Standardabweichung ist mit  $SE$  bezeichnet und wird aus der Wurzel der Varianz gebildet [74, S. 74].

Die Varianz der Verteilungsfunktion des logarithmierten Odds Ratios ist näherungsweise [74, S. 75] [98, S. 826]:

$$Var[\ln(OR)] = \frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d} = \frac{a+b}{ab} + \frac{c+d}{cd}. \quad (4.2)$$

Damit resultiert für die Standardabweichung  $SE$  des logarithmierten Odds Ratios:

$$SE[\ln(OR)] = \sqrt{\frac{a+b}{ab} + \frac{c+d}{cd}}. \quad (4.3)$$

Die Anwendung der Exponentialfunktion auf Gl. (4.1) transformiert das logarithmierte Odds Ratio zum Odds Ratio zurück:

$$OR e^{-z_{1-\alpha/2} SE[\ln(OR)]} \leq OR \leq OR e^{+z_{1-\alpha/2} SE[\ln(OR)]}. \quad (4.4)$$

Wenn das Intervall von Gl. (4.4) die 1 nicht mehr enthält, kann die Nullhypothese auf dem gewählten Signifikanzniveau abgelehnt werden.

Um die Vertrauenswürdigkeit der Ergebnisse speziell für diesen Datensatz zu erhöhen, wurde zusätzlich die minimale Fallanzahl von allen vier Häufigkeiten  $a$ ,  $b$ ,  $c$  und  $d$  auf jeweils 15 festgelegt. Seltene Kategorien, die im vorliegenden Datensatz auf Unfall- oder Baseline-Seite nicht oder nur kaum auftreten, fallen dadurch weg. Das OR-Intervall wird als zweiseitiges 95 % Konfidenzintervall angegeben, wodurch sich für das z-Quantil  $z_{1-\alpha/2} = 1,96$  ergibt [75, S. 265]. Es werden nur Ergebnisse dargestellt, die einen signifikanten Einfluss auf die Unfallwahrscheinlichkeit besitzen.

Zur Veranschaulichung wird das Vorgehen exemplarisch anhand der Kategorie „Dunkelheit – beleuchtet“ der Variable „Lichtbedingung“ gezeigt. Die zugehörige neutrale Kategorie zu „Dunkelheit – beleuchtet“ ist „Tageslicht“. Damit ergibt sich die Vierfeldertafel aus Tabelle 4.6.

Tabelle 4.6 Vierfeldertafel zur Berechnung des Einflusses der Kategorie „Dunkelheit – beleuchtet“

		Exposition		
		Dunkelheit - beleuchtet ( $E$ )	Tageslicht ( $\bar{E}$ )	$\Sigma$
Unfall	Unfall ( $K$ )	165	591	756
	Kein Unfall ( $\bar{K}$ )	2540	15482	18022
$\Sigma$		2705	16073	18778

Durch Berechnung von Gl. (2.3) und (4.4) resultiert ein Odds Ratio von 1,7 bei einem Konfidenzintervall von [1,4; 2]. Die Fahrt unter der Lichtbedingung „Dunkelheit – beleuchtet“ erhöht damit die Chance einen Unfall zu erleiden um den Faktor 1,7 im Vergleich zur neutralen Kategorie „Tageslicht“. Da das Konfidenzintervall den invarianten Wert 1 (kein Einfluss) nicht beinhaltet, kann der Einfluss auf die Unfallwahrscheinlichkeit als statistisch signifikant für ein zweiseitiges 95 % Konfidenzintervall angenommen werden. Die Ergebnisse bei einem analogen Vorgehen für alle Kategorien zeigt Abschnitt 4.4.



## 4.4 Ergebnis: Langsam veränderliches Kritikalitätsmaß

Die Ergebnisse zur Berechnung des langsam veränderlichen Kritikalitätsmaßes werden gegliedert in Umwelt (Kap. 4.4.1) sowie Fahrerzustand und Fahrmanöver (Kap. 4.4.2) dargestellt. Die zuvor in Kap. 4.3.2 getroffenen Einschränkungen mit einer Mindestfallanzahl und einer statistischen Signifikanz der Ergebnisse verringern die in diesem Kapitel dargestellten Einflusskategorien von 231 auf 62.

### 4.4.1 Umwelt

Tabelle 4.7 zeigt die quantifizierten, langsam veränderlichen Umwelteinflüsse auf die Unfallwahrscheinlichkeit. Es lassen sich drei Arten von möglichen kausalen Zusammenhängen zwischen Umweltkategorien und der Erhöhung der Unfallwahrscheinlichkeit identifizieren. So wirken erstens einige dargestellte Einflüsse wie eine schneebedeckte oder nasse Straße direkt auf die Fahrdynamik, indem sie den maximalen Kraftschlussbeiwert zwischen Reifen und Straße reduzieren. Damit wird bei kritischen Szenarien die Handlungsfähigkeit durch Notbremsung und/oder Ausweichen eingeschränkt und es kommt bei sonst gleicher Ausgangssituation tendenziell öfter zu Unfällen.

Eine weitere Möglichkeit des Zusammenhangs besteht über die assoziierte Verkehrsumgebung. In engeren Situationen wie Parkplätzen inklusive deren Ein- und Ausfahrten, innerstädtischen Gebieten oder Kreuzungen sind Kollisionen mit statischen Objekten oder anderen Verkehrsteilnehmern allein schon wegen der räumlichen Enge wahrscheinlicher. Eine kurze Zeitspanne einer Nicht-Reaktion führt hier zwangsläufig schnell zu Unfällen. Es ist anzunehmen, dass die Unfallschweren in dieser Umgebung aufgrund langsamerer Geschwindigkeiten geringer sind.

Ein dritter möglicher Zusammenhang zwischen Umwelt und Unfallwahrscheinlichkeit besteht über den Fahrer: Widrige Wetterbedingungen wie Regen oder Schneefall beziehungsweise Dunkelheit beeinträchtigen die Umfeldwahrnehmung des Fahrers. Kommt dieser den eingeschränkten Sichtverhältnissen nicht ausreichend durch eine angepasste Fahrweise nach, entsteht damit ebenso eine erhöhte Unfallwahrscheinlichkeit. Ein weiterer wichtiger, den Fahrer betreffender Punkt stellt die Komplexität der Fahrsituation dar. So erscheinen vor allem Umweltsituationen, die den Fahrer besonders fordern, wie Kreuzungen mit unterschiedlichen Verkehrsregelungen, Baustellen, die oben bereits erwähnten Parkplätze oder zählfließender Verkehr als negativ beeinflussend.

Alle hier quantifizierten, die Unfallwahrscheinlichkeit senkenden Einflüsse lassen sich auf eine ähnliche Art erklären. Sie betreffen durchwegs die Senkung der Fahrkomplexität. Sei es durch das Befahren von schlichten Außerortsstraßen, dem Vorhandensein von mehreren Fahrstreifen in eigener Fahrtrichtung oder dem Fahren in flüssigem Verkehr. Jedoch ist zu beachten, dass eine Unterforderung des Fahrers, wie bei der verwendeten neutralen Kategorie „Freifahrt ohne Vorderfahrzeug“, bei zu geringerer Fahrkomplexität und Belastung zu einer niedrigeren Leistungsfähigkeit des Fahrers führt [99, S. 24].

## 4 Quantifizierung langsam veränderlicher Einflussfaktoren

Tabelle 4.7 Quantifizierung von langsam veränderlichen Umwelteinflüssen

Untersuchte Kategorie	Neutrale Kategorie	OR	95 % Konfidenz Intervall
Schneebedeckte Straße	Trockene Straße	9	6,2 13,1
Schneefall	Keine Beeinträchtigung durch Wetter	7,5	4,8 11,6
In Parkplatz	Keine Kreuzungsnähe	6,5	5 8,3
Kein erreichbarer Fahrstreifen	2 erreichbare Fahrstreifen	5,5	4,4 7
Andere Verkehrsregelung	Keine Verkehrsregelung	5,2	3,3 8,2
Kein Fahrstreifen in eigener Fahrtrichtung	1 Fahrstreifen in eigener Fahrtrichtung	4,3	3,5 5,2
Keine Fahrstreifen	2 Fahrstreifen (nicht geteilt)	4,1	3,3 5,1
Ampel	Keine Verkehrsregelung	3	2,4 3,7
Stoppschild	Keine Verkehrsregelung	3	2,3 4
1 erreichbarer Fahrstreifen	2 erreichbare Fahrstreifen	2,6	1,9 3,5
Geschwindigkeits- oder anderes Warnschild	Keine Verkehrsregelung	2,5	1,7 3,6
In Kreuzung	Keine Kreuzungsnähe	2,5	2 3
Straßenmarkierungen als einzige Verkehrsregelung	Keine Verkehrsregelung	2,2	1,4 3,5
In Kreuzungsnähe	Keine Kreuzungsnähe	2,2	1,8 2,8
Nieselregen oder leichter Regen	Keine Beeinträchtigung durch Wetter	1,9	1,5 2,6
Parkplatz - Einfahrt oder Ausfahrt	Keine Kreuzungsnähe	1,8	1,4 2,4
Dunkelheit - beleuchtet	Tageslicht	1,7	1,4 2
Level D: Zählfließend mit temporären Einschränkungen	Level A1: Freifahrt ohne Vorderfahrzeug	1,7	1,1 2,6
In Baustelle	Keine Baustellennähe	1,6	1,1 2,3
Nasse Straße	Trockene Straße	1,5	1,3 1,8
Einbahnstraße	2 Fahrstreifen (nicht geteilt)	1,5	1,1 2
Einfahrt, Auffahrt etc.	Keine Kreuzungsnähe	1,5	1,1 1,9
Innerstädtisch	Gewerbegebiet	1,5	1 2,1
Gefälle	Ebener Straßenverlauf	1,4	1 1,9
Rechtskurve	Gerader Straßenverlauf	1,3	1 1,7
Level B: Fließend mit einigen Einschränkungen	Level A1: Freifahrt ohne Vorderfahrzeug	0,7	0,6 0,8
Geteilte Fahrbahnen für jede Fahrtrichtung	2 Fahrstreifen (nicht geteilt)	0,5	0,4 0,6
Ungeteilte Fahrbahn mit Zwei-Wege-Mittelfahrstreifen	2 Fahrstreifen (nicht geteilt)	0,5	0,4 0,7
2 Fahrstreifen in eigener Fahrtrichtung	1 Fahrstreifen in eigener Fahrtrichtung	0,5	0,5 0,6
4 Fahrstreifen in eigener Fahrtrichtung	1 Fahrstreifen in eigener Fahrtrichtung	0,5	0,3 0,7
Level A2: Freifahrt mit Vorderfahrzeug	Level A1: Freifahrt ohne Vorderfahrzeug	0,5	0,4 0,6
3 Fahrstreifen in eigener Fahrtrichtung	1 Fahrstreifen in eigener Fahrtrichtung	0,4	0,3 0,6
Umgehungsstraße oder geteilte Autobahn mit Ampeln	Gewerbegebiet	0,4	0,3 0,7
Fernstraße, Umgehungsstraße oder geteilte Autobahn ohne Ampeln	Gewerbegebiet	0,3	0,2 0,3

### 4.4.2 Fahrerzustand und Fahrmanöver

Neben den eher indirekt auf den Fahrer wirkenden Einflüssen aus der Umwelt adressiert dieser Abschnitt direkt das Verhalten, die Nebentätigkeiten, die Beeinträchtigungen und die gefahrenen Manöver des Fahrers (Tabelle 4.8).

Prinzipiell erzeugt jede zusätzliche Aufgabe neben der Fahraufgabe eine höhere Belastung des Fahrers. Das kann sich in den Fahrer unterfordernden Situationen auf dessen Leistungsfähigkeit positiv auswirken [99, S. 24]. Bei normalen bis überdurchschnittlichen Belastungen führt jedoch eine weitere Belastungssteigerung zu einer Überforderung des Fahrers. Dadurch sinkt seine Leistungsfähigkeit und erhöht wiederum die Unfallwahrscheinlichkeit.

Tabelle 4.8 Quantifizierung von langsam veränderlichen Einflüssen aus Fahrerzustand und Fahrmanöver

Untersuchte Kategorie	Neutrale Kategorie	OR	95 %		
			Konfidenzintervall		
Geradeausfahrt mit unabsichtlichem Abdriften im oder über den eigenen Fahrstreifen	Geradeausfahrt bei konstanter Geschwindigkeit	23	15,9	33,1	
Rechts abbiegen	Geradeausfahrt bei konstanter Geschwindigkeit	21,5	16,5	28	
Einparken	Geradeausfahrt bei konstanter Geschwindigkeit	20,9	14,7	29,7	
Links abbiegen	Geradeausfahrt bei konstanter Geschwindigkeit	18,2	13,6	24,3	
Greifen nach Objekt	Keine Nebentätigkeit des Fahrers	17,3	12	25	
Beobachten eines Objektes außerhalb des Fahrzeuges	Keine Nebentätigkeit des Fahrers	9,3	6,2	13,9	
Schreiben am Smartphone	Keine Nebentätigkeit des Fahrers	5,9	4,4	7,9	
Keine Hand am Lenkrad	Nur linke Hand am Lenkrad	5,4	4	7,3	
Bedienung anderer festeingebauter Geräte im Fahrzeug	Keine Nebentätigkeit des Fahrers	4,6	2,9	7,5	
Nebentätigkeit (andere)	Keine Nebentätigkeit des Fahrers	4,5	2,8	7,3	
Fahrstreifenwechsel	Geradeausfahrt bei konstanter Geschwindigkeit	3,7	2,4	5,5	
Geradeaus beschleunigen	Geradeausfahrt bei konstanter Geschwindigkeit	3,2	2,4	4,2	
Fahrer beschäftigt sich mit Objekt im Fahrzeug	Keine Nebentätigkeit des Fahrers	3	1,9	4,5	
Durchfahren einer Kurve	Geradeausfahrt bei konstanter Geschwindigkeit	2,6	2	3,4	
Sicherheitsgurt nicht angelegt	Sicherheitsgurt richtig angelegt	2,5	1,9	3,2	
Verzögern in eigenem Fahrstreifen	Geradeausfahrt bei konstanter Geschwindigkeit	2,3	1,8	3	
Persönliche Hygiene	Keine Nebentätigkeit des Fahrers	2,2	1,3	3,6	
Müde, schläfrig, schlafend	Keine Beeinträchtigung des Fahrers	2	1,3	3	
Telefonieren mit Smartphone in der Hand	Keine Nebentätigkeit des Fahrers	2	1,4	2,8	
Unspezifische Blickzuwendung innerhalb des Fahrzeugs	Keine Nebentätigkeit des Fahrers	2	1,4	2,9	
Sicherheitsgurt nicht richtig angelegt	Sicherheitsgurt richtig angelegt	1,8	1,1	3,1	
Radio bedienen	Keine Nebentätigkeit des Fahrers	1,7	1,1	2,7	
Essen ohne Utensilien (wie z.B. Besteck)	Keine Nebentätigkeit des Fahrers	1,7	1	2,9	
Sprechen, Singen, Telefonieren mit Freisprechanlage	Keine Nebentätigkeit des Fahrers	1,7	1,3	2,2	
Andere Ablenkung außerhalb des Fahrzeugs	Keine Nebentätigkeit des Fahrers	1,5	1,2	2	
Interaktion mit Passagier auf Vordersitz	Keine Nebentätigkeit des Fahrers	1,5	1,2	1,8	
Zwei Passagiere auf Vordersitzen	Nur Fahrer auf Vordersitz	0,7	0,6	0,9	
Ein Passagier auf Rücksitz	Kein Passagier auf Rücksitzen	0,5	0,4	0,8	

Das bestätigen die Ergebnisse bezüglich den Nebentätigkeiten. So führt ausnahmslos jede Nebentätigkeit zu einer Erhöhung der Unfallwahrscheinlichkeit. Wie in der Literatur festgestellt (Kap. 2.2.2), wirken sich komplexe Nebentätigkeiten wie das Bedienen von Smartphones und anderen festverbauten Geräten oder das Greifen nach Objekten besonders negativ aus. Das Beobachten eines Objektes außerhalb des Fahrzeugs zeigt ebenso einen großen Einfluss. Allen gemein ist die dafür nötige Blickabwendung des Fahrers vom relevanten Verkehrsgeschehen. In solchen Zeitspannen des „Blindflugs“ kommt es unweigerlich zu Kollisionen, sobald das Verkehrsgeschehen eine Fahrerreaktion benötigen würde. Besonders in engen Verkehrsumgebungen mit vielen potentiellen Kollisionsobjekten (innerstädtisch) und bei höheren Geschwindigkeiten mit großen überfahrenen Flächen pro Zeiteinheit (außerorts) steigt damit die Unfallwahrscheinlichkeit.

Eine wahrnehmbare Fahrerbeeinträchtigung durch Müdigkeit verhält sich betragsmäßig ähnlich den moderaten und einfachen Nebentätigkeiten mit OR zwischen 1,5 und 2,2. Diese Art der Nebentätigkeiten erschweren zwar das Ausüben der Fahraufgabe, lässt aber zumindest regelmäßige, kontrollierende Blicke auf das Verkehrsgeschehen zu. Sonstige Beeinträchtigungen des Fahrers neben der Müdigkeit konnten mit den getroffenen Einschränkungen nicht statistisch signifikant nachgewiesen werden.

Das sonstige Fahrerverhalten im Fahrzeug umfasst das Anlegen des Sicherheitsgurts, der Anzahl der Hände am Lenkrad sowie das Vorhandensein von weiteren Passagieren. So erhöht ein nicht richtig angelegter Sicherheitsgurt die Unfallwahrscheinlichkeit um den Faktor 1,8, während ein überhaupt nicht angelegter Sicherheitsgurt diese um den Faktor 2,5 ansteigen lässt. Mögliche Erklärungsansätze könnten in Persönlichkeitsmerkmalen wie dem subjektiven Sicherheitsempfinden oder dem bewussten Begehen von Verkehrsverstößen liegen, die sich auch zur Unfallprognose eignen [57].

Das Fahren ohne Hand am Lenkrad beeinflusst vergleichbar mit komplexen Nebentätigkeiten die Unfallwahrscheinlichkeit stark mit dem OR Wert von 5,4. Da unter diesem Zustand keine erforderlichen Lenkreaktionen möglich sind, scheint die Deutlichkeit der Ausprägung sinnvoll.

Das Vorhandensein von jeweils einem zusätzlichen Passagier auf Vorder- und Rücksitzen wirkt sich positiv auf die Fahrzeugsicherheit aus. Ein Passagier auf dem Rücksitz halbiert sogar die Unfallwahrscheinlichkeit. Für die Fälle von mehreren zusätzlichen Passagieren auf den Rücksitzen konnte keine signifikante Aussage getroffen werden.

Den stärksten Einfluss auf die Unfallwahrscheinlichkeit zeigt die Variable „Pre-Incident Manöver“. Darin ist das zum Untersuchungszeitpunkt (bei Baseline-Fällen) beziehungsweise das letzte vor einem Unfall gefahrene Manöver angegeben. Es wird deutlich, dass jede Änderung zur neutralen Kategorie „Geradeausfahrt bei konstanter Geschwindigkeit“ eine ausgeprägte Verschlechterung der Unfallwahrscheinlichkeit nach sich zieht. Bei Manövern wie Kurvenfahrt, Verzögern oder Beschleunigen mit eher niedriger Komplexität führt das zu Werten zwischen 2,3 und 3,2. Ein Fahrstreifenwechsel wird bereits mit 3,7 quantifiziert. Bei Manövern hoher Komplexität wie dem Abbiegen können hohe Werte um den Faktor 20 nachgewiesen werden. Den höchsten Wert erreicht die Kategorie „Geradeausfahrt mit unabsichtlichem Abdriften im oder über den eigenen Fahrstreifen“ mit dem Faktor 23. Diese Kategorie geht über eine reine Manöverbeschreibung hinaus. Darin implizit enthalten ist auch die Umschreibung einer unabsichtlichen Fahrhandlung, die sogar ein Verlassen der geplanten Fahrspur und/oder des eigenen Fahrstreifens zur Folge hat. Ein Zusammenhang dieser Kategorie mit den eingangs erwähnten, komplexen Nebentätigkeiten des Fahrers ist denkbar, jedoch anhand dieser Analyse nicht zu beweisen. Die Verbindung dieser Kategorie mit einer eingeschränkten Leistungsfähigkeit des Fahrers erscheint dennoch sinnvoll.

## 4.5 Diskussion

### 4.5.1 Anwendungsmöglichkeiten der Ergebnisse

Der direkte Einfluss von langsam veränderlichen Einflussfaktoren auf die Unfallwahrscheinlichkeit ist vergleichsweise groß. Unter Annahme eines durchschnittlichen Wertes von 3,3 Unfällen pro 1 Mio. Fahrzeugkilometer für polizeilich erfasste Unfälle [100, S. 6] ergibt sich jedoch durch Multiplikation mit den berechneten Faktoren aus Kap. 4.4 ein relativ niedriger, absoluter Unfallwahrscheinlichkeitswert. Dieser ermöglicht kein eigenes Fahrerassistenzsystem mit Warnungen oder Auslösungen, weil ein zugehöriger Aussagezeitpunkt in obiger Auswertung nicht enthalten ist. Ferner sind alle hier betrachteten Variablen nicht beliebig lange im Voraus verfügbar. Trotzdem ist der zu bewertende Zeithorizont größer als bei der reinen Betrachtung von schnell veränderlichen Fahrzeugzeitreihendaten.

Eine Verrechnung der oben bestimmten Odds Ratios  $OR_i$  mit  $i = 1 \dots I$  Einflussfaktoren für jedes Event  $j = 1 \dots J$  der betrachteten Daten (Kap. 4.1) zu einer langsam veränderlichen Eventbewertung  $EB_j$  ergibt

$$EB_j = \log \left( \prod_{i=1}^I OR_i \right). \quad (4.5)$$

Die in Boxplots aufgetragenen Eventbewertungen  $EB_j$  für alle Sequenzen  $j = 1 \dots J$  liefern eine Abschätzung, wie stark die langsam veränderlichen Einflussfaktoren den Datensatz in Baselines und Unfälle auftrennen können (Abb. 4.3). Jede Box enthält den Median sowie das obere und untere Quartil. Die maximale Länge der Antenne ist das 1,5-fache des Abstandes zwischen oberem und unterem Quartil. Ein rotes Kreuz kennzeichnet Ausreißer außerhalb der Antennen. Die Boxen für Baseline und Unfall zeigen keine Überlappung. Das Maß zur langsam veränderlichen Eventbewertung  $EB_j$  bewertet die beiden untersuchten Gruppen hinreichend unterschiedlich. Es ist deshalb berechtigt anzunehmen, dass eine Weiterverwendung der langsam veränderlichen Einflussfaktoren zusammen mit weiteren Größen für eine prädiktive Klassifikation von Unfallsequenzen in Kapitel 5 sinnvoll ist [101].

Alle Ergebnisse entstammen der SHRP2 Studie, die bei Erstellung der Baselinedaten versucht hat, mit dem Datensatz das Fahrer-, Umgebungs- und Fahreventkollektiv genau dieser Studie nachzubilden. Deshalb ist eine weitere Nutzung der Ergebnisse nur sinnvoll, wenn sie sich auf das gleiche Kollektiv beziehen.

Neben der Verwendung in einer prädiktiven Klassifikation lässt sich das Vorgehen der Odds Ratio Analyse ebenso für die Szenarienauswahl zur Entwicklung von prädiktiven, aktiven Sicherheitsfunktionen verwenden. Damit können in Szenariendatenbanken koexistierende, risik erhöhende Faktoren identifiziert [102] und damit repräsentative Szenarien zur Funktionsentwicklung ausgewählt werden [103].

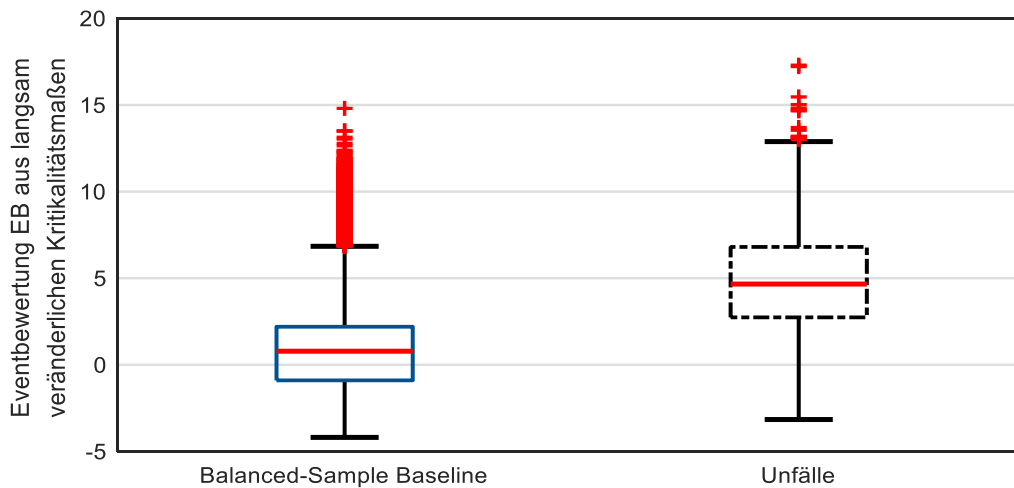


Abb. 4.3 Auftrennung des Datensatzes über langsam veränderliche Einflussfaktoren

### 4.5.2 Datenerhebungsaufwand eines OEM mit Fahrzeugflotte

Der Datenerhebungsaufwand zur Generierung signifikanter Ergebnisse ist für jede zu untersuchende Kategorie unterschiedlich. Je deutlicher das OR vom Wert 1 abweicht, desto eher beinhaltet das Konfidenzintervall nicht mehr die 1 und der Einfluss kann als signifikant angenommen werden (Gl. (4.4)). Für einen OEM, der gezielt für sein eigenes Datenkollektiv, bestehend aus Fahrzeugen, Fahrern und Umgebung, die OR Einflüsse bestimmen will, ist jedoch eine andere Abschätzung notwendig. Der Datenerhebungsaufwand skaliert mit der Mindeststichprobengröße  $n_{min}$  mit einer tolerierten Abweichung  $\epsilon$  für die Schätzung eines Odds Ratios durch ein  $(1-\alpha)\%$ -Konfidenzintervall wie folgt [75, S. 662]:

$$n_{min} = \left[ \frac{1}{P_1(1-P_1)} + f \frac{1}{P_2(1-P_2)} \right] \left( \frac{z_{1-\alpha/2}}{\ln(1-\epsilon)} \right)^2 \quad (4.6)$$

Hierbei werden die Wahrscheinlichkeiten  $P_1$  und  $P_2$  aus der Vierfeldertafel (Tabelle 4.5) zu  $P_1 = P(E|K)$  und  $P_2 = P(E|\bar{K})$  bestimmt. Der Faktor  $f$  ist das Verhältnis der Unfall- zu den Nicht-Unfall-Events.

Es kann ebenso die Mindeststichprobengröße für exponierte und nicht-exponierte Unfälle angegeben werden:

$$n_{exponiert} = n_{min} \cdot P_1 \quad (4.7)$$

$$n_{nicht\_exponiert} = n_{min} - n_{exponiert} \quad (4.8)$$

Eine Datenerhebungsflotte müsste demnach für jede zu untersuchende Kategorie eine eigene Mindeststichprobengröße an exponierten Unfällen  $n_{exponiert}$  enthalten. Aus den Werten für  $n_{min}$  und  $n_{exponiert}$  ließe sich über eine Abschätzung der Unfälle pro Kilometer die nötige Fahrleistung berechnen und damit der Aufwand einer Fahrzeugflotte quantifizieren. Der verwendete Datensatz aus SHRP2 enthält in keiner Kategorie genug Fälle, um mit einer tolerierten Abweichung von höchstens 10% ein zweiseitiges 95%- Konfidenzintervall für das

OR berechnen zu können. Für die in Kap. 4.5.1 dargestellte weitere Anwendungsmöglichkeit der Ergebnisse als Merkmal in einem prädiktiven Schätzprozess stellt das kein Problem dar. Dennoch würde die funktionale Absicherung eines auf OR-Werten basierenden, aktiven Fahrzeugsicherheitssystems diese Konfidenz benötigen.

Ebenso müsste ein OEM eine monetäre Bewertung vornehmen. Jede durch einen Flottenversuch erhebbare Kategorie ist dabei individuell zu beurteilen. Der jeweilig erzielbare Erlös des Informationsmehrwertes beziehungsweise das Verbesserungspotential für eine Fahrzeugsicherheitsfunktion muss monetär bewertet werden. Der Aufwand an nötigen Fahrzeugkilometern inklusive der Datenaufzeichnung, Datenhaltung und Datenauswertung steht dem gegenüber. Die betriebswirtschaftlich motivierte Durchführung eines Flottenversuchs besitzt demzufolge a priori eine klare Eingrenzung der zu bestimmenden Kategorien sowie den zugehörigen Mindestfallanzahlen.

### 4.5.3 Ausblick einer zeit- und ortsbasierten Analyse

Das dargestellte Vorgehen ist aufgrund der verwendeten Datenbasis auf in der Eventtabelle enthaltene Variablen beschränkt. Zusätzliche Informationen zu Zeit und Ort ließen sich äquivalent behandeln. Zeiteinflüsse könnten über Kategorien wie Tageszeitraum, Wochentag, Tagart (Werktag, Feiertag, Urlaubswerktag etc.) oder Monate diskretisiert und untersucht werden. Für Orte würde sich eine gitter- oder streckenabschnittsbasierte Aufteilung anbieten. Eine genügend große Datenbasis könnte sogar eine Diskretisierung mit kombinierten raum-zeitlichen Elementen ermöglichen [93][101][104][105][106]. Wenn zusätzlich je Ort-/Zeit-Element eine Normierung mit der Verkehrsleistung erfolgt, beinhaltet jedes Element einen quantitativ aussagekräftigen Unfallwahrscheinlichkeitswert in der Einheit Unfall pro km. Eine weitere Anwendung der Ergebnisse als Merkmale in einer prädiktiven Klassifikation, wie in Kap. 4.5.1 beschrieben, liefere analog ab.

Diese Informationen ließen sich in einer Navigationsaufgabe zur Routenauswahl weiterverwenden. Dazu müssten lediglich die Unfallwahrscheinlichkeitswerte aller raum-zeitlichen Elemente aufsummiert werden. Das beschriebene Vorgehen geht deutlich über vorhandene Ansätze hinaus: NAJADA und MAHGOUB [107] nutzen makroskopisch erwartete Unfälle zur Routenaktualisierung. HONGLEI et al präzisieren mit einem Deep Learning Ansatz erwartete Unfallzahlen in diskretisierten Zeit- und Ortselementen [108]. Eine Normierung über die vorliegende Verkehrsleistung findet jedoch nicht statt. SPIELMAN et al [109] beziehen Wetterbedingungen in ein Flottenmanagementsystem ein. RYDER et al detektieren örtliche Unfallhäufungspunkte und zeigen diese dem sich nähernden Fahrer ohne zusätzlichen Bezug zur aktuellen Fahrsituation an [110].





# 5 Prädiktive Kritikalitätsschätzung von Unfallsequenzen mit maschinellem Lernen

In diesem Kapitel wird die prädiktive Kritikalitätsschätzung von Unfallsequenzen behandelt. Die Schätzung basiert auf schnell veränderlichen Größen wie Zeitreihensignalen aus der Fahrdynamik oder der Umgebungssensorik. Zusätzlich werden die Erkenntnisse von langsam veränderlichen Einflussfaktoren auf die Unfallwahrscheinlichkeit (Kap. 4) miteinbezogen. Dazu erfolgt zunächst eine Beschreibung der verwendeten Zeitreihendaten der SHRP2 Studie (Kap. 5.1). Es schließt sich eine Datenvorverarbeitung sowie der begründete Ausschluss von fehlerhaften Datensätzen an (Kap. 5.2). Der Abschnitt 5.3 beschreibt das Vorgehen. Darin wird zuerst ein Methodenüberblick zum Stand der Wissenschaft der Klassifikationsmethoden gegeben. Es folgen die nötigen Schritte zur Vorbereitung einer Modellerzeugung mit maschinellem Lernen wie Merkmalerzeugung, Merkmalsauswahl, Parametrisierung der Methoden und Auswahl einer Bewertungsgröße. Abschließend gibt Kap. 5.3.7 einen Überblick, welche Auswertungsvariationen mit welchen Auswertungszielen konkret umgesetzt werden. Die sich daraus ergebenden Ergebnisse werden in Kap. 5.4 dargestellt und diskutiert. Das Vorgehen wurde bereits in [111] veröffentlicht.

## 5.1 Stand der Wissenschaft: Zeitreihendaten der SHRP2 Studie

In Kapitel 4.1 wurden bereits allgemeine Informationen zur verwendeten Studie SHRP2 sowie zu den nachträglich aus Videos bestimmten Eventdaten gegeben. Im Gegensatz zu den kategorialen Variablen aus Abschnitt 4.1 bestehen die Zeitreihendaten jedes Datensatzes aus 30 s langen Signaldaten. Dieser Abschnitt geht speziell auf die aufgezeichneten Zeitreihendaten der Studie ein.

Die Fahrzeuge der Studie wurden mit mehreren Sensoren ausgerüstet [94, S. 45 ff][112]. Eine sogenannte Head-Unit nahe des Rückspiegels enthält vier Kameras zur Aufnahme eines Weitwinkelvideos der vorderen Fahrzeugumgebung, eines Videos des Armaturenbretts, eines Fahrervideos und eines gelegentlich ausgelösten Bildes des gesamten Fahrzeuginnenraums. Zusätzlich nimmt eine weitere Kamera ein Video des rückwärtigen Verkehrsgeschehens auf. Eine Übersicht der einzelnen Sichtbereiche der installierten Kameras, eines Beispielframes der aufgezeichneten Videos und der installierten Head-Unit zeigt Abb. 5.1. Um die aufgezeichneten Pixel besser auszunutzen, ist das Fahrervideo vorläufig um 90° gedreht. Die Head-Unit enthält zudem einen passiven Alkoholsensor, einen Helligkeitssensor und Beschleunigungs- und Drehratensensoren in alle drei Raumrichtungen.

Am vorderen Kennzeichenhalter befindet sich ein Radarsensor, der Objekte des vorderen Fahrzeugumfelds detektiert (Abb. 5.2). Eine GPS-Antenne am hinteren Fahrzeugdach liefert die Position, eine Höhenmessung, die Zeit und eine Geschwindigkeit [112].

Zusätzlich werden Bussignale aus der OBD- (On-Board-Diagnose) Schnittstelle gewonnen. Diese umfassen unter anderem Informationen zu Gaspedal und Bremspedalstellung, Gang, Lenkradwinkel, Geschwindigkeit, Hupe oder Fahrtrichtungsanzeiger. Falls das Fahrtrichtungssignal nicht über den Fahrzeug-Bus ausgelesen werden kann, wird dieser direkt an den Blinkleuchten der Fahrzeugfront erhoben.

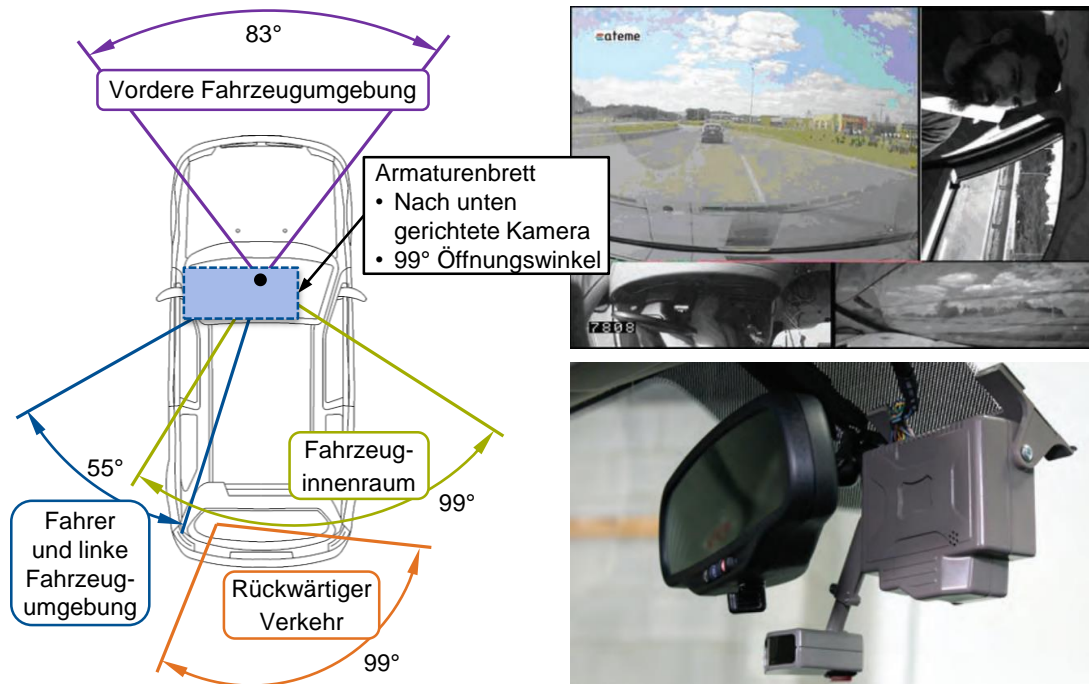


Abb. 5.1 Sichtbereiche der Kameras der SHRP2 Studie (links), Beispielvideoframe (rechts oben), Head-Unit (rechts unten) nach [112, S. 32]

Alle erhobenen Zeitreihendaten werden in eine fahrzeugintegrierte Datenaufzeichnungseinheit (DAS Data Acquisition System) im Kofferraum geleitet und darin aufgezeichnet (Abb. 5.2). Zudem laufen darauf einige Computer Vision Algorithmen wie zum Beispiel eine Fahrstreifen-erkennung. Ungeachtet der ursprünglichen Abtastfrequenz der Sensorrohdaten sind alle Videosignale mit 15 Hz aufgezeichnet, alle Signale, die die Fahrdynamik und Umgebungswahrnehmung betreffen, mit 10 Hz.



Abb. 5.2 Front-Radarsensor am Kennzeichenhalter (links), Fahrzeugintegrierte Datenaufzeichnungseinheit (rechts) [112]

Einen Überblick zu allen aufgezeichneten Zeitreihendaten der SHRP2 Studie liefert Abb. 5.3. Für weitere Informationen zur Datenerfassung sei auf [94] verwiesen.

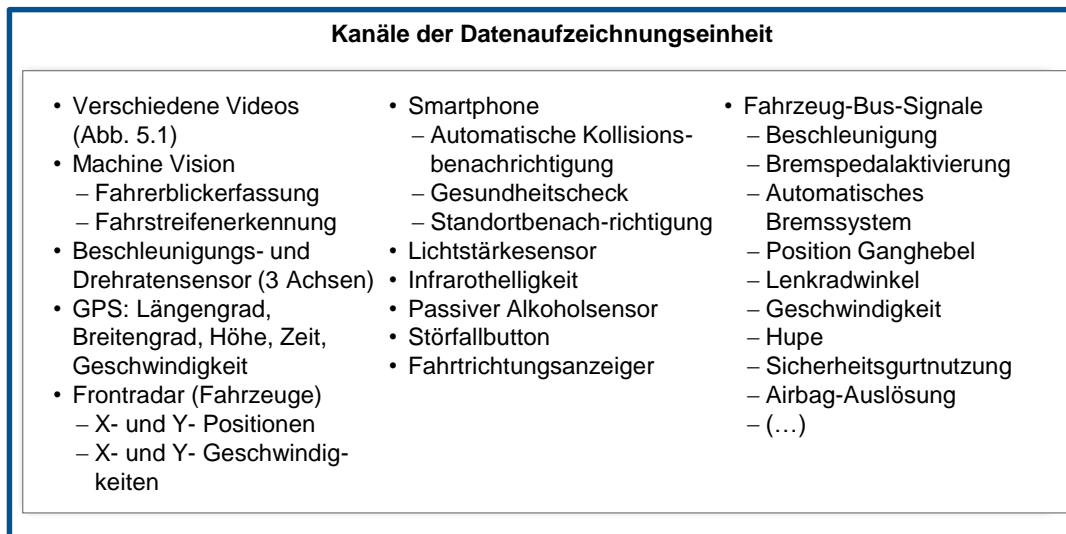


Abb. 5.3 Aufgezeichnete Daten der SHRP2 Studie nach [112, S. 32]

Die hier zugängliche und verwendete Teilmenge der Studiendaten ist auf die Zeitreihensignale von Tabelle 5.1 beschränkt [95].

## 5 Prädiktive Kritikalitätsschätzung von Unfallsequenzen mit maschinellem Lernen

Tabelle 5.1 Verwendete Zeitreihendaten aus SHRP2 [95]

Variable	Einheit/Wertebereich	Beschreibung
Zeitstempel	ms	Zeit seit Fahrtbeginn
ID_Fahrt	-	ID der Fahrt
$v_{GPS}$	km/h	Fahrzeuggeschwindigkeit aus dem GPS-Signal
$v$	km/h	Fahrzeuggeschwindigkeit aus dem Fahrzeug-Bus
$a_x$	g	Fahrzeugbeschleunigung in longitudinaler Richtung
$a_y$	g	Fahrzeugbeschleunigung in lateraler Richtung
$a_z$	g	Fahrzeugbeschleunigung in vertikaler Richtung
$\dot{\psi}$	grad/s	Gierrate
Bremspedal- position	0=off, 1=on, 2= Daten ungültig, 3=Daten nicht verfügbar	Status der Bremspedalposition
Gaspedal- position	-	Gaspedalposition aus dem Fahrzeug-Bus
Lenkradwinkel	grad	Lenkradwinkel (gemessen aus neutraler Position)
Fahrtrichtungs- anzeiger	0=aus, 1=links, 2=rechts, 3=beide, 254/255=ungül- tige/keine Daten	Status des Fahrtrichtungsanzeigers
ABS	0=nicht aktiv, 1=aktiv	Antiblockiersystem (ABS)
ESP	0=nicht aktiv, 1=aktiv	Elektronisches Stabilitätsprogramm (ESP)
ASR	0=nicht aktiv, 1=aktiv	Antriebsschlupfregelung (ASR)
Scheiben- wischer	0=nicht aktiv, 1=gele- gentlich, 2=langsam, 3=schnell, 254/255= un- gültige/keine Daten	Scheibenwischereinstellung
Abblendlicht	0=off, 1=on	Status des Abblendlichts
ID_Objekt	-	ID eines getrackten Objekts
$x_{pos}$	m	Distanz des Objekts zum Ego in x-Richtung (Geisterobjekte entfernt, Objektkandidaten vereint, Daten geglättet)
$y_{pos}$	m	Distanz des Objekts zum Ego in y-Richtung (Geisterobjekte entfernt, Objektkandidaten vereint, Daten geglättet)
$x_{vel}$	m/s	Relativgeschwindigkeit des Objekts zum Ego in x-Richtung (Geisterobjekte entfernt, Objektkandidaten vereint, Daten geglättet)
$y_{vel}$	m/s	Relativgeschwindigkeit des Objekts zum Ego in y-Richtung (Geisterobjekte entfernt, Objektkandidaten vereint, Daten geglättet)
$x_{acc,est}$	m/s <sup>2</sup>	Geschätzte Relativbeschleunigung des Objekts zum Ego in x-Rich- tung
Bewegungs- richtung_ Objekt	2 = gleich wie Ego 1 = stationär 0 = stationär (immer) -1 = stationär -2 = Gegenrichtung 99 = unbekannt	Bewegungsrichtung des Objekts 2 = Objekt bewegt sich in gleicher Fahrtrichtung wie Ego 1 = stationäres Objekt, davor/danach 2 zugeordnet 0 = stationäres Objekt für alle beobachteten Zeitschritte -1 = stationäres Objekt, davor/danach -2 zugeordnet -2 = Objekt bewegt sich in Gegenrichtung zu Ego 99 = unbekannt
Fahrstreifen_ Objekt	2 = weit rechts 1 = rechter Fahrstreifen 0 = gleicher Fahrstreifen -1 = linker Fahrstreifen -2 = weit links null = Gegenverkehr	Fahrstreifen des Objekts 2 = mind. ein Fahrstreifen (rechts) zwischen Objekt und Ego 1 = Objekt ist auf anliegendem rechten Fahrstreifen zum Ego 0 = Objekt ist auf gleichem Fahrstreifen wie Ego -1 = Objekt ist auf anliegendem linken Fahrstreifen zum Ego -2 = mind. ein Fahrstreifen (links) zwischen Objekt und Ego null = Gegenverkehr ist keinem Fahrstreifen zugeordnet
Vorderfahr- zeug_Objekt	1 = Vorderfahrzeug 0 = nicht Vorderfahrzeug	Ist das Objekt Vorderfahrzeug?
THW (Time Head Way (engl.), Zeitlücke)	s	Zeitlücke = $(x_{pos}) / (\text{Objektgeschwindigkeit})$

## 5.2 Datenvorverarbeitung

Dieser Abschnitt geht auf die nötigen Datenvorverarbeitungsschritte für die Klassifikation der Datensequenzen näher ein. Zunächst geschieht das für die Zeitreihendaten (Kap. 5.2.1), anschließend für die langsamen Kritikalitätsmaße (Kap. 5.2.2) aus dem vorherigen Kapitel 4.

### 5.2.1 Zeitreihendaten

Die Zeitreihendaten sind teilweise fehlerhaft. Das folgt zum einen aus dem heterogenen Versuchsaufbau mit vielen verschiedenen Fahrzeugtypen und der nachgerüsteten Messsensorik, die der Zuverlässigkeit von serienmäßig verbauten Systemen nicht ebenbürtig ist. Zum anderen ist denkbar, dass durch die zuvor in 5.1 erwähnte Umwandlung der Abtastrate Messdatenfehler entstanden sind. Beides resultiert schließlich in fehlenden Werten für die Geschwindigkeit  $v$ , der Gierrate  $\dot{\psi}$  sowie den Beschleunigungen  $a_x$ ,  $a_y$  und  $a_z$ . Die Fahrtrichtung in den Radardaten ist ebenso oftmals nicht korrekt oder fehlt sogar. Die durchgeführten Möglichkeiten zur Rekonstruktion des ursprünglichen Datenmaterials orientieren sich an [113] und werden im Folgenden vorgestellt.

In den Fahrdynamikgrößen  $v$ ,  $\dot{\psi}$ ,  $a_x$ ,  $a_y$  und  $a_z$  können zuerst über lineare Interpolation einzelne fehlende Werte der Zeitreihe rekonstruiert werden. Dadurch erreichen die Variablen Gierrate  $\dot{\psi}$  sowie die Beschleunigungen  $a_x$ ,  $a_y$  und  $a_z$  nahezu Vollständigkeit.

Auf die aus dem Fahrzeug-Bus ausgelesene Geschwindigkeit  $v$  trifft dies nicht zu. Wegen der zu geringen Abtastrate von 1 Hz der Geschwindigkeit aus dem GPS-Signal kann diese nicht als Alternative genutzt werden. Zur Rekonstruktion des Geschwindigkeitssignals wird deshalb die Beschleunigung mitverwendet. Der Prozess läuft in folgenden Schritten ab:

- Integration der Beschleunigung zu einer integrierten Geschwindigkeit
- Differenzenbildung mit verfügbarem Geschwindigkeitssignal (aus Bussignal (bevorzugt) oder GPS)
- Medianfilterung der Differenz
- Addition der mediangefilterten Differenzgeschwindigkeit auf die integrierte Geschwindigkeit
- Glättung des korrigierten Geschwindigkeitsverlaufs mit Savitzky-Golay-Filter

Durch die Medianfilterung der Differenz kann ein Offset in der Beschleunigung aufgrund einer Steigung oder eines Gefälles kompensiert werden.

Zur Rekonstruktion der Angabe der Fahrtrichtung für Radarobjekte wird zuerst die absolute Objektgeschwindigkeit  $v_{Obj,abs}$  aus der eigenen Fahrzeuggeschwindigkeit und der zugehörigen Relativgeschwindigkeit in x-Richtung aus dem Radarsensor bestimmt. Als Zuordnungsvorschrift dienen folgende Signalgrenzen:

- für  $v_{Obj,abs} > 10$  km/h: gleiche Fahrtrichtung
- für  $v_{Obj,abs} < -10$  km/h: Gegenrichtung
- sonst: ruhendes Objekt

Der betragsmäßige Schwellwert von 10 km/h ist aufgrund der vorliegenden Messungenauigkeiten empirisch gewählt.

Bei Datensätzen, in denen sowohl das Beschleunigungs- als auch das Geschwindigkeitssignal fehlen, ist eine derartige Rekonstruktion nicht möglich. Diese werden im Folgenden nicht weiter verwendet. Aus der Datenvorverarbeitung der Zeitreihendaten resultieren schließlich 840 Unfall- sowie 19.600 Baseline-Sequenzen.

### 5.2.2 Weiterverwendung langsam veränderlicher Kritikalitätsmaße

In Kapitel 4 wurde für 20 kategoriale Variablen und insgesamt 231 zugehörige Kategorien der Einfluss auf die Unfallwahrscheinlichkeit bestimmt. Diese langsam veränderlichen Kritikalitätsmaße werden nun wieder auf die zu untersuchenden Datensätze bezogen. Jeder Datensatz ist eindeutig mit einer Event-ID bezeichnet. Es ergibt sich damit eine Eventbewertung aus den Odds Ratio der Kategorien für alle 20 kategorialen Variablen, wie Tabelle 5.2 exemplarisch zeigt. Das Odds Ratio einer Kategorie  $Kat_i$  (z. B. Regen) kann demnach in der zugehörigen Variablen  $Var$  (z. B. Wetter) in mehreren Datensätzen auftreten.

Tabelle 5.2 Exemplarische Eventbewertung mit langsam veränderlichen Kritikalitätsmaßen zur Weiterverwendung im prädiktiven Schätzprozess

Event ID	Eventtyp	Variable <sub>1</sub>	...	Variable <sub>20</sub>
2834107	Unfall	$OR_{Var_1, Kat_i}$	...	$OR_{Var_{20}, Kat_m}$
2843842	Unfall	$OR_{Var_1, Kat_l}$	...	$OR_{Var_{20}, Kat_p}$
⋮	⋮	⋮	...	⋮
151569221	Baseline	$OR_{Var_1, Kat_j}$	...	$OR_{Var_{20}, Kat_n}$
151569222	Baseline	$OR_{Var_1, Kat_i}$	...	$OR_{Var_{20}, Kat_p}$

Jede neutrale Kategorie geht mit einem  $OR = 1$  ein. Tabelle 5.2 dient als Ausgangspunkt zur Erzeugung von entscheidungsrelevanten Merkmalen in Kap. 5.3.3.

## 5.3 Vorgehen: Klassifikation der Datensequenzen

Dieser Abschnitt beschreibt das Vorgehen zur Klassifikation der Datensequenzen. Zuerst werden die relevanten Methoden des maschinellen Lernens aus dem Stand der Wissenschaft vorgestellt (Kap. 5.3.1). Die Klassifikation wird mit verschiedenen Datensatzkombinationen durchlaufen, die in Kap. 5.3.2 näher beschrieben werden. Die Erzeugung und Auswahl von Merkmalen, die Parametrisierung und Detaillierung der Methoden sowie die Wahl einer Bewertungsgröße stellen notwendige vorbereitende Schritte dar (Kap. 5.3.3 - 5.3.6). Alle durchlaufenen Auswertungsvariationen aus Datensätzen, verwendeten Merkmalen und genutzter Methode sind in Kap. 5.3.7 beschrieben. Das Ziel ist letztendlich die Klassifikation von Sequenzen in Baseline-Fälle und Unfälle. Die dafür notwendigen Merkmale stammen aus einem Zeitfenster mehrere Sekunden vor dem Unfall. Als Ergebnis sollen Aussagen bezüglich der erreichten Klassifikationsgüte, dem Verlauf eines kontinuierlichen Kritikalitätsmaßes sowie der zugehörigen Wichtigkeit von Merkmalen generiert werden (Kap. 5.4). Einen Überblick zum Aufbau des Abschnitts gibt Abb. 5.4.

Das Vorgehen dieses Kapitels basiert in Teilen auf der zu diesem Thema vom Autor konzipierten und betreuten Studienarbeit von YE [113].

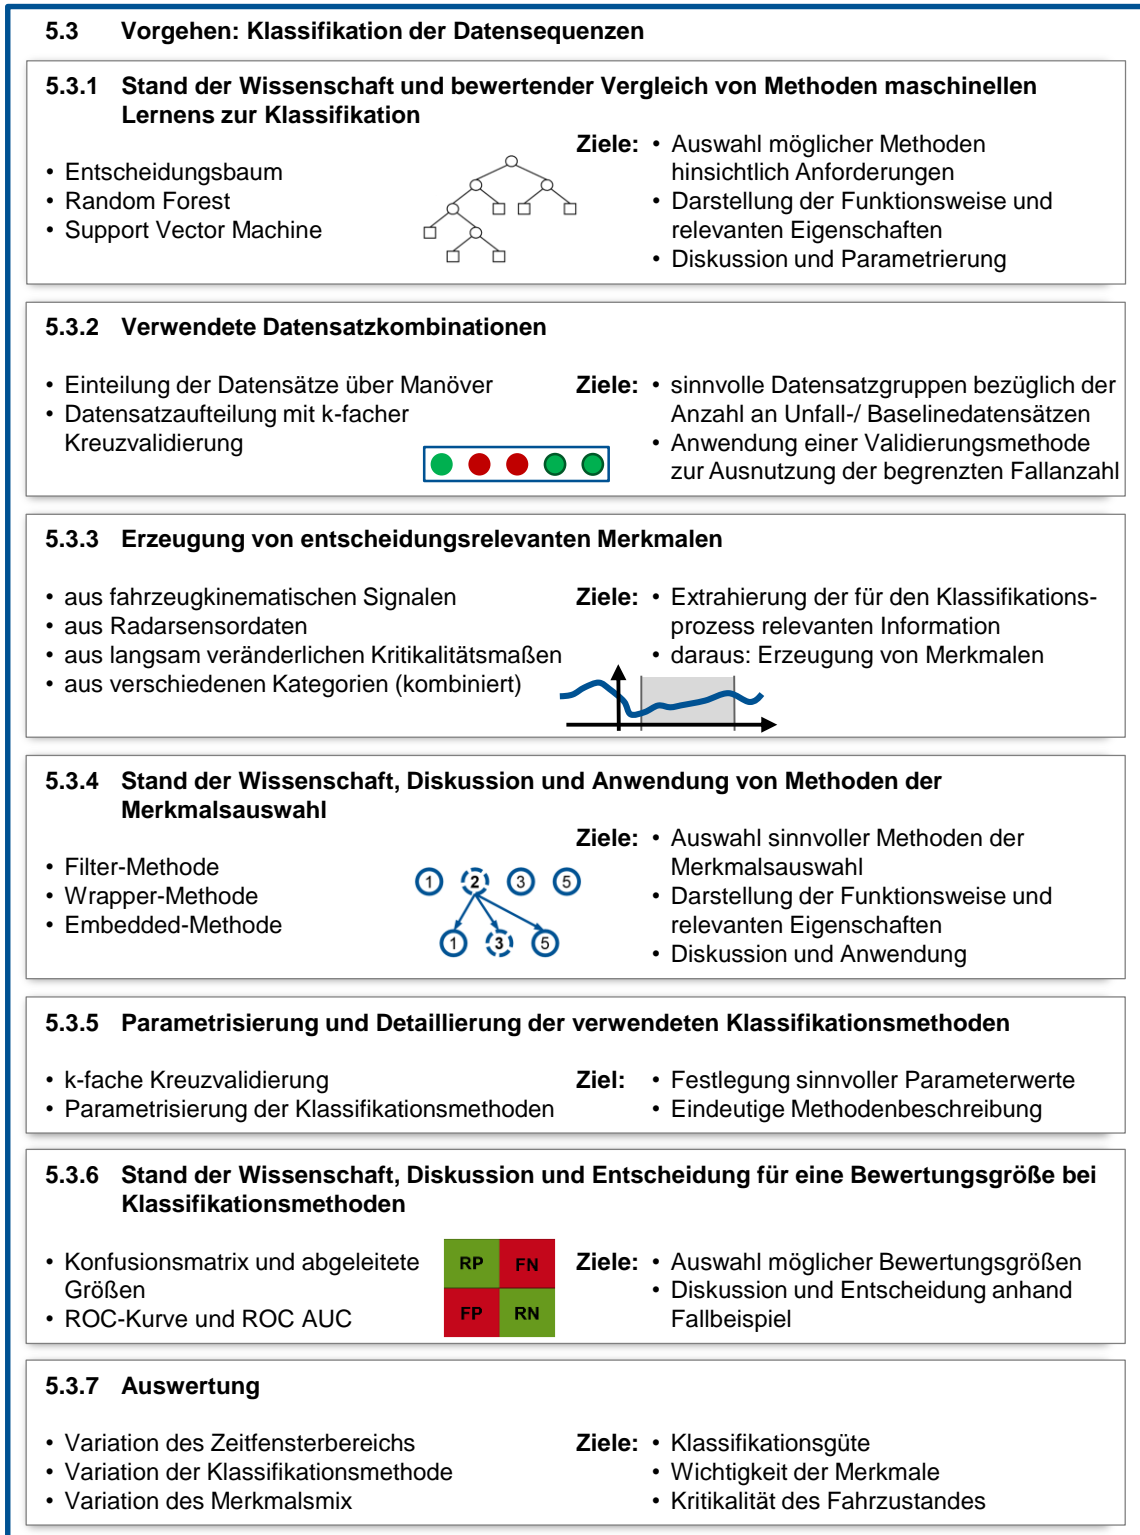


Abb. 5.4 Aufbau des Vorgehens

### 5.3.1 Stand der Wissenschaft: Methoden maschinellen Lernens zur Klassifikation

Das Ziel von maschinellem Lernen ist, ausgehend von Beispieldatensätzen, die Muster oder Gesetzmäßigkeiten einer Problemstellung zu erlernen [114, S. 1]. Sind die Beispieldaten einer Problemstellung bereits mit Zielwerten wie Klassenzugehörigkeiten versehen, spricht man von überwachten Lernmethoden [115, S. 2]. Ein Lernprozess ohne vorgegebene Zielwerte zählt zu den unüberwachten Lernmethoden. Klassifikationsmethoden gehören, wie auch Regressionsmethoden, zum überwachten Lernen, während Clustermethoden dem unüberwachten Lernen zugeordnet werden (Abb. 5.5).

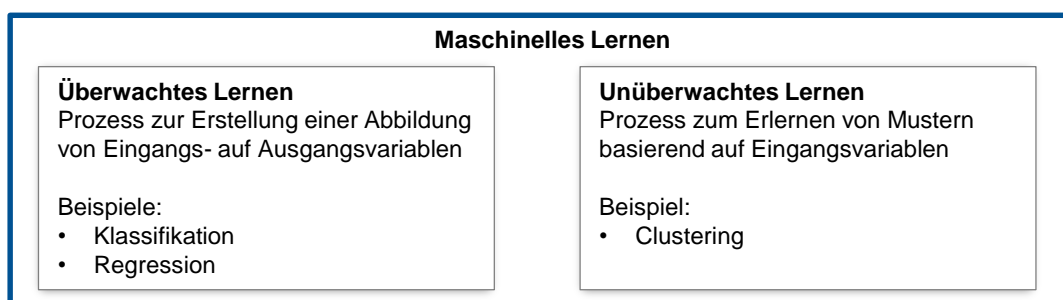


Abb. 5.5 Einteilung maschineller Lernmethoden nach [115, S. 2]

Im Unterschied zur kontinuierlichen Schätzung einer Zielgröße bei der Regression versucht eine Klassifikation diskrete Klassen zu schätzen. Die Problemstellung in beiden Verfahren kann als Funktionsapproximation gesehen werden [116, S. 10]. Zusätzlich können viele Klassifikationsmethoden ebenso für Regressionsaufgaben verwendet werden. Eine mögliche Einteilung von Klassifikationsmethoden liefern KOTSIANTIS, ZAHARAKIS und PINTELAS [117][118]:

- Logikbasierte Algorithmen: Entscheidungsbäume, Regelbasierte Lerner (Rule Learners)
- Perzeptronbasierte Techniken: Ein-Schicht-Perzeptrenen, Mehr-Schicht-Perzeptrenen (wie Künstliches Neuronales Netz)
- Statistische Lernalgorithmen: Naiver Bayes Klassifikator, Bayes'sches Netz
- Instanzbasierte Methoden: k-Nearest-Neighbor-Algorithmus (kNN)
- Support Vector Machines (SVM)

Die Anforderungen an die verwendete Methode sind vielfältig. Sie soll interpretierbare Ergebnisse erlauben, eine ausreichende Klassifikationsgenauigkeit besitzen und, bedingt durch die Datenqualität der SHRP2 Daten, geringe Anforderungen an die Eingangsdaten im Trainingsprozess haben. Eine Gegenüberstellung anhand einiger möglicher Bewertungskategorien von Lernalgorithmen zeigt Tabelle 5.3.

Ein Vergleich von Lernalgorithmen ist stark abhängig von der Problemstellung. Generelle Empfehlungen gestalten sich schwierig, weil in empirischen Vergleichen selbst die besten Methoden mitunter schlechte Ergebnisse liefern [119, S. 167]. Trotzdem erfolgt hier eine Entscheidung für zwei weiter verwendete Algorithmen. Zum einen wird der Lernalgorithmus Random Forest verwendet. Dieses Verfahren basiert auf dem Zusammenschluss von mehreren Entscheidungsbäumen. Dadurch kann die Klassifikationsgenauigkeit eines einzelnen Entscheidungsbaums weiter erhöht werden, die Robustheit gegenüber schlechter Eingangsdatenqualität bleibt jedoch erhalten. Zum Vergleich der erhaltenen Genauigkeit kommt mit der



Support Vector Machine (SVM) eine Methode mit ähnlich hoher allgemeiner Genauigkeit zum Einsatz.

Tabelle 5.3 Bewertender Vergleich von Lernalgorithmen (Auszüge aus [118] und [120])

Bewertungskategorie	Entscheidungs- bäume	Random Forest	Neuronale Netze	Naïve Bayes	kNN	SVM	Rule Learners
Allgemeine Genauigkeit	++	++++	+++	+	++	++++	++
Klassifikationsgeschwindigkeit	++++	+++	++++	++++	+	+++	++++
Toleranz gegenüber irrelevanten Attributen	+++	+++	+	++	++	++++	++
Toleranz gegenüber redundanten Attributen	++	++	++	+	++	+++	++
Interpretierbarkeit / Transparenz der Klassifikation	++++	+++	+	++++	++	+	++++

(++++ steht für die beste, + für die schlechteste Bewertung)

Im weiteren Verlauf dieses Kapitels wird auf die Funktionsweise und Eigenschaften der verwendeten Methoden eingegangen. Dabei soll zuerst der Entscheidungsbaum vorgestellt werden. Im Anschluss folgt seine Erweiterung auf den Random Forest, der als Hauptalgorithmus dieser Arbeit fungiert. Zur Überprüfung der durch den Random Forest generierten Ergebnisse dient die Support Vector Machine, die abschließend vorgestellt wird. Alle gezeigten Algorithmen finden sowohl in der Klassifikation als auch in der Regression Anwendung. Da jedoch der Hauptfokus dieser Arbeit auf der binären Klassifikation liegt, soll auch primär darauf eingegangen werden.

## Entscheidungsbaum

Erstmals wurde der CART-Algorithmus (*engl.* Classification and Regression Tree) zur Erzeugung eines Entscheidungsbaums 1984 von BREIMAN et al. veröffentlicht [121]. Das Verfahren versucht mit der automatischen Erzeugung von Entscheidungsregeln einen Datensatz in eine Zielklasse einzuordnen [116, S. 305-306]. Die Visualisierung dieser Entscheidungsregeln kann mit Hilfe einer baumförmigen Struktur erfolgen (Abb. 5.6). Die Menge aller Datensätze wird für jeden Knoten  $N_i$  anhand der am Knoten vorliegenden Bedingungen in kleinere Gruppen aufgeteilt. Die Bedingungen überprüfen für das zugehörige Merkmal  $x_i$ , ob dessen Wert ober- oder unterhalb eines Splitwertes liegt. Da jeder Knoten genau in zwei Zweige aufgespaltet wird, nennt man die Unterteilung binär. Die Knoten nach der letzten Teilung werden als Endknoten  $L_i$  oder Blätter bezeichnet. Diesen sind ganze Klassen  $K_i$  zugeordnet. Bei Auswertung eines neuen Datensatzes werden alle Bedingungen bis zu einem Endknoten durchlaufen, der dann die Zielklasse festlegt. Im Folgenden wird für den CART-Algorithmus der Begriff Entscheidungsbaum verwendet.

In dieser Arbeit stehen die Zielklassen  $K_1$  und  $K_2$  für Unfall- und Baseline sequenzen. Ein Entscheidungsbaum kann nun den gesamten Eingangsdatensatz am Knoten  $N_1$  mit Hilfe des Merkmals  $x_1$  auftrennen. Als Merkmal könnte beispielsweise die durchschnittliche Geschwindigkeit der Sequenzen in einem festgelegten Zeitfenster vor einem Unfall dienen. Die detaillierte Beschreibung der Merkmalerzeugung erfolgt in Kap. 5.3.3. Oberhalb eines bestimmten Geschwindigkeitswertes wird der Datensatz am Knoten  $N_2$  weiter aufgeteilt, unterhalb am Knoten  $N_3$ . Die Wahl des Merkmals und der Splitbedingung wird im folgenden

Abschnitt genauer beschrieben. Nach der vollständigen Baumkonstruktion mit Hilfe von Trainingsdaten kann ein neuer Datensatz anhand der Knotenbedingungen einem Endknoten und damit einer Zielklasse zugeordnet werden.




Abb. 5.6 Beispiel eines Entscheidungsbaums [113, S. 28]

**Konstruktion**

Entscheidend bei der Konstruktion des Entscheidungsbaums ist die Bestimmung des Merkmals und die zugehörige Merkmalsbedingung eines jeden Knotens [121, S. 24-43]. Jeder Split soll mit Hilfe der Trainingsdaten zu einer möglichst guten Trennung der wahren Klassen führen. Dafür wird ein Maß  $i(N)$  für die Unreinheit (*engl.* Impurity) der Datensätze eines Knoten  $N$  benötigt. Eine Möglichkeit für dieses Maß ist der Gini Index of Diversity [122, S. 67]:

$$i(N) = 1 - \sum_{j=1}^n p_j(N)^2, \tag{5.1}$$

wobei  $n$  für die Anzahl der Klassen und  $p_j(N)$  für die relative Häufigkeit der  $j$ -ten Klasse am Knoten  $N$  steht. Die Summe der relativen Häufigkeiten aller Klassen an einem Knoten addiert sich zu 1, damit gilt:  $\sum_{j=1}^n p_j(N) = 1$ . Das Maß erreicht für den Fall von nur einer einzigen Klasse am Knoten sein Minimum. Das Maximum entstünde, wenn alle Klassen am Knoten gleich häufig auftreten würden. Laut GILLES LOUPE [123, S. 46] hat die Auswahl des Unreinheitsmaßes nur einen geringen Einfluss auf die Klassifikationseigenschaften des finalen Entscheidungsbaums. Aus diesem Grund wird mit dem Gini index of diversity nur das gebräuchlichste Maß vorgestellt und verwendet.

Um einen beliebigen Split  $s$  zu bewerten, kann die Differenz zwischen den Unreinheitsmaßen am Ausgangsknoten  $N$  und den darauffolgenden linken und rechten Knoten  $N_L$  beziehungsweise  $N_R$  gebildet werden:

$$\Delta i(N, s) = i(N) - p_L i(N_L) - p_R i(N_R). \tag{5.2}$$

$p_L$  und  $p_R$  sind die Datensatzanteile in den Folgeknoten  $N_L$  beziehungsweise  $N_R$ . Je größer die Differenz der Unreinheitsmaße  $\Delta i(N, s)$  ist, desto besser (reiner) erfolgte die Trennung am jeweiligen Knoten. Der systematische Vergleich von vielen möglichen Splitvarianten, bestehend aus Wahl des Merkmals und Merkmalsbedingung, erlaubt das Identifizieren der besten Splitoption mit dem größten Wert für  $\Delta i(N, s)$ .

Die Methode kann nun fortgeführt werden, bis der Ausgangsdatsatz vollständig in seine Klassen aufgeteilt ist. Jedoch wäre damit das Modell erheblich überangepasst (*engl.* overfitted) und könnte nicht für ungesehene Datensätze verwendet werden. Aus diesem Grund ist eine Abbruchbedingung erforderlich. Oft verwendete Stopp-Kriterien zur Regulierung der Größe der Bäume sind [115, S. 546]:

- Minimale Anzahl an Datensätzen in einem Blatt
- Maximale Anzahl an Splits für den gesamten Baum
- Minimale Verbesserung des Unreinheitsmaßes an einem Knoten  $(\Delta i)_{min}$

Bei letzterem Kriterium kann jedoch bei einem schlechten Split der Konstruktionsvorgang abgebrochen werden, obwohl möglicherweise gut trennende Splits folgen würden. Da die Ergebnisse der erwähnten Stopp-Kriterien nicht zufriedenstellend waren, entwickelte BREIMAN et al. [121, S. 59-71] die Pruning-Methode (*engl.* stutzen): Ausgangspunkt ist die Konstruktion eines Baums mit möglichst vielen Verzweigungen. Diesem werden anschließend anhand einer Kostenfunktion die Zweige wieder „gestutzt“ und Knoten zusammengelegt. Obiges Problem, dass der Konstruktionsvorgang trotz besserer nachfolgender Splits verfrüht abgebrochen wird, tritt damit nicht mehr auf.

Nach erfolgtem Baumwachstum erhält jedes Blatt eine Wahrscheinlichkeit für eine Klassenzugehörigkeit. Diese ergibt sich aus der relativen Häufigkeit einer Klasse in Bezug auf alle Datensätze eines Blattes. Die Klasse mit der höchsten relativen Häufigkeit wird zur Zielklasse des Blattes [115, S. 544].

### Eigenschaften

Durch den Konstruktionsprozess läuft implizit eine automatische Merkmalsauswahl nach der Embedded-Methode (*engl.* eingebettet) ab [124, S. 80-81]: Für jeden Split wird nur das relevanteste Merkmal ausgewählt, die unwichtigen Merkmale werden im gesamten Konstruktionsprozess nicht einbezogen. Je wichtiger ein Merkmal, desto weiter oben ist es in der Baumstruktur angesiedelt. Damit ist eine einfache Ermittlung der wichtigsten Entscheidungsregeln möglich, wodurch der Entscheidungsbaum als gut interpretierbar eingestuft wird.

Vorteilhaft sind darüber hinaus die geringen Anforderungen an die Eingangsdaten für den Trainingsprozess. Bedingt durch die verwendete Größer-/ Kleiner-Logik ist der Algorithmus robust gegenüber Ausreißern [124, S. 34] sowie Skalierungen in den Merkmalen [124, S. 174]. Eine Normierung der Merkmalsausprägungen ist damit nicht nötig, wodurch die Splitwerte auch interpretierbar bleiben. Zudem müssen Datensätze mit fehlenden Merkmalswerten nicht aussortiert werden, weil jeder Knoten über mehrere Ersatz-Splits (*engl.* surrogate splits) verfügt [121, S. 140-150]. Diese wurden beim Baumwachstum an einem Knoten zwar nicht als beste Splitoption ausgewählt, trennen den Datensatz jedoch ähnlich zum verwendeten Split auf. Sie können somit bei Fehlen des ursprünglichen Merkmalswertes als Alternativen verwendet werden.

Ein wichtiger Vorteil des Entscheidungsbaums ist die Möglichkeit, die relative Wichtigkeit einzelner Merkmale für die Zielgrößenbestimmung einzuschätzen [121, S. 146-147]. Durch

Aufsummieren der Verbesserungen des Unreinheitsmaßes  $\Delta i(N, s)$  für jedes Merkmal über alle Knoten hinweg entsteht ein qualitativer Vergleichswert für jedes Merkmal. Aus diesem kann wiederum eine Rangliste zur Wichtigkeit der Merkmale generiert und für Interpretationszwecke genutzt werden.

Nachteilig beim Entscheidungsbaum ist die Modellinstabilität bei der Konstruktion der Entscheidungsregeln [124, S. 174]. Kleine Änderungen in der Zusammensetzung der Trainingsdatensätze können zu stark unterschiedlichen Baumstrukturen führen. Ein Ergebnisvergleich von Bäumen aus unterschiedlichen Trainingsdatenzusammensetzungen ist damit erschwert. Ein weiterer Nachteil des Entscheidungsbaums ist die im Vergleich zu anderen Methoden geringere Genauigkeit bei der Prädiktion [116, S. 351][118][120]. Die Ursache lässt sich anhand einer grafischen Repräsentation von Entscheidungsregeln für einen zweidimensionalen Merkmalsraum darlegen (Abb. 5.7). Die schraffierte Fläche entspricht dem wahren Bereich der Klasse. Die Entscheidungslogik versucht diesen mit Entscheidungsregeln abzubilden. Dadurch ergeben sich die hellen Rechtecke, die äquivalent zur Baumstruktur einem Blatt entsprechen und einer Zielklasse zugeordnet sind. Wenn der Bereich für eine Klasse nur schwer durch Rechtecke abzubilden ist, sinkt die Performance der Prädiktion [124, S. 174]. Der Nachteil einer geringeren Genauigkeit bei der Prädiktion lässt sich durch die Kombination von mehreren Bäumen zu einem Modell kompensieren, wie der nächste Abschnitt zeigt.

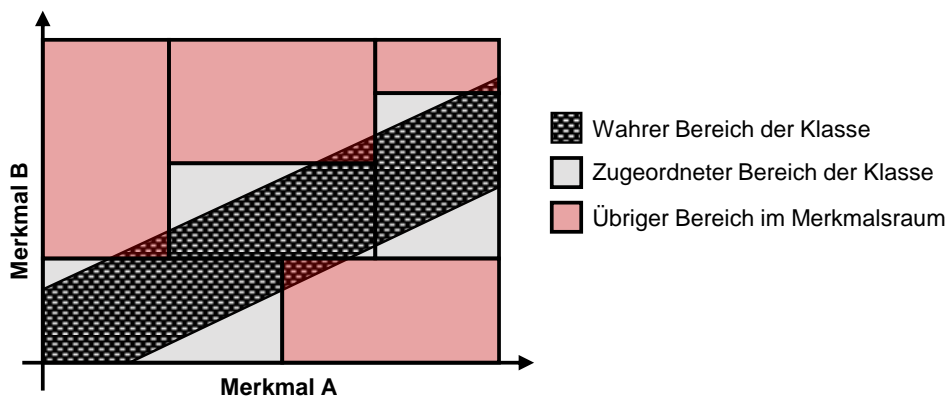


Abb. 5.7 Einteilung eines zweidimensionalen Merkmalsraums in Rechtecke nach [113, S. 30]

## Random Forest

Der Random Forest stammt aus der Gruppe der Ensemble Learning Methoden, die Prädiktionen einzelner Modelle kombinieren und daraus eine Aussage für das Gesamtmodell generieren [116, S. 605]. BREIMAN [125] publizierte 2001 erstmals den Random Forest. Es werden hierbei mehrere Entscheidungsbäume unterschiedlicher Struktur verknüpft. Die Auswertung erfolgt durch Mittelung der Prädiktionen aller Teilmodelle, sodass die Klassifizierung einem Mehrheitsentscheid entspricht. Dadurch verbessert sich die als gering einzuschätzende Prädiktionsgüte eines einzelnen Entscheidungsbaums [116, S. 587].

### Bagging und Random Input Selection

Die Erzeugung eines Entscheidungsbaums mit dem CART-Algorithmus verläuft deterministisch. Solange gleiche Trainingsdatensätze und Modellparameter vorliegen, ist auch die Struktur des Baums identisch. Um Bäume unterschiedlicher Struktur zu erhalten, werden in den Trainingsprozess Zufälligkeiten eingebracht. Eine mögliche Methode hierfür heißt Bagging (*engl.* **bootstrap aggregation**) und gilt als Vorläufer des Random Forests [124, S. 192-198].

Bagging realisiert die Datensatzauswahl nach dem Prinzip „Ziehen mit Zurücklegen“. Die damit ausgewählte Anzahl an Datensätzen ist gleich der Anzahl aller Datensätze. Dadurch kommen einige Datensätze mehrfach, etwa ein Drittel der Datensätze jedoch überhaupt nicht im Trainingsprozess vor [124, S. 72-73]. Am Konstruktionsvorgang nach dem CART-Algorithmus verändert sich nichts. Nach der Erstellung mehrerer Entscheidungsbäume wird für die Prädiktion die Mittelung über die Ergebnisse der einzelnen Bäume verwendet. Damit reduziert sich beim Bagging der Varianzfehler deutlich und senkt die Gefahr zur Überanpassung, wohingegen ein einzelner Entscheidungsbaum steigender Größe durchaus zur Überanpassung neigt. Je geringer die Ähnlichkeit der gebildeten Baumstrukturen, desto positiver wirkt sich dieser Effekt auf die Performance aus.

Bei der Weiterentwicklung des Bagging zum Random Forest werden weitere Zufallsfaktoren in den Modellerzeugungsprozess eingebunden [124, S. 198-203]. Das senkt die zuvor als Ähnlichkeit der Baumstrukturen bezeichnete Korrelation zwischen den Bäumen. Jedem Knoten steht hier statt allen Merkmalen nur noch eine zufällige Auswahl davon für die Splitbildung zur Verfügung. BREIMAN [125, S. 11-14] bezeichnet diesen Schritt zur zusätzlichen Randomisierung als Random Input Selection. Neben diesem Kernelement wird jeder einzelne Baum bis zur maximalen Größe erzeugt, was zu einer maximalen Überanpassung führt. Damit ist der Varianzfehler maximal, der Biasfehler minimal. Durch die bereits beschriebene Mittelung über die Ergebnisse aller Bäume reduziert sich der Varianzfehler schließlich wieder.

### Eigenschaften

Als Weiterentwicklung des Entscheidungsbaums übernimmt der Random Forest viele von dessen Vorteilen:

- geringe Anforderungen an die Eingangsdaten
- integriertes Verfahren zur Merkmalsauswahl
- Möglichkeit zur Bestimmung der relativen Wichtigkeit einzelner Merkmale

Letzteres geschieht äquivalent zum Entscheidungsbaum durch die Mittelwertbildung der relativen Wichtigkeit der Merkmale über alle Bäume [116, S. 593]. Mit der Erzeugung vieler verschiedener Bäume geht jedoch der Vorteil der Interpretierbarkeit verloren [124, S. 198]. Ein einfaches Verständnis des Modells wie beim einzelnen Entscheidungsbaum ist beim Random Forest nicht möglich.

Vorteilhaft ist hingegen die hervorragende Leistungsfähigkeit in der Prädiktion, bedingt durch den reduzierten Varianzfehler [125, S. 10]. Diese reicht sogar an die AdaBoost-Methode von FREUND UND SCHAPIRE [126] heran, die von BREIMAN [116, S. 340] selbst vor Veröffentlichung des Random Forest als „best off-the-shelf classifier in the world“ bezeichnet wurde. Die AdaBoost-Methode gehört ebenso wie der Random Forest zu den Ensemble Learning Methoden. Da die Bäume beim Random Forest keine Abhängigkeiten untereinander aufweisen, erhöht sich, im Vergleich zur AdaBoost-Methode, die Robustheit gegenüber Rauscheffekten sowie die Parallelisierbarkeit im Konstruktionsprozess.

Die geringe Anzahl an einzustellenden Parametern erweist sich als weiterer Vorteil des Random Forest. Die Konstruktion der Entscheidungsbäume erfolgt immer bis zur maximalen Größe und benötigt daher kein Abbruch-Kriterium. Als Einstellkriterien verbleiben lediglich die Anzahl der an jedem Knoten verfügbaren Merkmale  $m_{try}$  und die Anzahl der Entscheidungsbäume des Gesamtmodells  $n_{tree}$  [124, S. 199-200]. Wegen des geringen Einflusses von  $m_{try}$  auf die Leistungsfähigkeit wird häufig die Verwendung des Standardwerts  $m_{try} = \sqrt{q}$

vorgeschlagen, wobei  $q$  für die Anzahl aller Merkmale steht [116, S. 592]. Dieser Wert für  $m_{try}$  wird auch in dieser Arbeit verwendet. Die richtige Anzahl der Entscheidungsbäume  $n_{tree}$  hängt vom Anwendungsfall ab und stellt einen Kompromiss zwischen Leistungsfähigkeit und Rechenaufwand dar. Je höher die Anzahl  $n_{tree}$ , desto höher ist auch die Leistungsfähigkeit des Gesamtmodells, wobei sie nach dem Gesetz der großen Zahlen gegen einen Grenzwert konvergiert [125, S. 7]. Der Rechenaufwand steigt dabei linear mit der Anzahl der Bäume.

Zusammenfassend zeichnet sich der Random Forest aufgrund seiner Robustheit gegenüber unvollständigen Datensätzen und geringwertiger Datenqualität aus. Gleichzeitig ermöglicht er eine hohe Leistungsfähigkeit in der Prädiktion bei einer geringen Anzahl an einzustellenden Modellparametern. Deshalb soll die Methode zur weiteren Untersuchung der SHRP2 Studien- daten als Hauptklassifikator fungieren.

## Support Vector Machine

Die ersten Anfänge der Support Vector Machine (SVM) reichen zurück bis in die Mitte der 1960er Jahre [124, S. 343]. Sie entwickelte sich zu einem der effektivsten maschinellen Lern- verfahren und wurde 1995 von CORTES UND VAPNIK [127] mit einer umfassenden Beschreibung veröffentlicht. Ursprünglich als binärer Klassifikator eingesetzt, wurde die SVM später auch auf den Bereich der nichtlinearen Regression erweitert [124, S. 151]. Die folgende Darstellung basiert auf einer häufig zitierten Einführung in die SVM als Klassifikator zur Mustererkennung von BURGESS [128].

### Lineare SVM

Hier soll der einfachste Fall einer linearen SVM mit separierbaren Datensätzen gezeigt werden [128, S. 128-134]. Die Erweiterung auf die nichtlineare SVM mit nicht-separierbaren Daten- sätzen erfolgt im nächsten Abschnitt. Ausgangspunkt sind  $l$  Trainingsdatensätze  $\{x_i, y_i\}, i = 1, \dots, l$  mit dem  $q$ -dimensionalen Merkmalsvektor  $x_i \in \mathbb{R}^q$  und der binären Zielklasse  $y_i \in \{-1, 1\}$ . Es wird eine Hyperebene gesucht, die beide Klassen voneinander trennt. Die Gleichung

$$f(x) = w \cdot x + b = 0 \tag{5.3}$$

beschreibt die Punkte dieser Ebene, wobei  $w$  den Normalenvektor der Hyperebene darstellt und die Steigung von  $f(x)$  in Richtung  $x$  angibt. Der senkrechte Abstand zwischen Ebene und Ursprung ist  $|b|/\|w\|$ .  $\|w\|$  bezeichnet hier die euklidische Norm von  $w$ .

Außerdem sei  $d_+(d_-)$  der kürzeste Abstand zwischen der trennenden Hyperebene und dem am nächsten liegenden Datensatz der Klasse  $+1$  ( $-1$ ). Die Summe  $d_+ + d_-$  entspricht einer Abstandsreserve der Hyperebene zur Trennung der beiden Datensätze. Diese Abstandsreserve soll in folgender Herleitung maximiert werden.

Man nehme an, dass die Funktion  $f(x)$  folgende Bedingungen erfüllt:

$$f(x_i) = x_i w + b \geq +1 \quad \text{für } y_i = +1, \tag{5.4}$$

$$f(x_i) = x_i w + b \leq -1 \quad \text{für } y_i = -1. \tag{5.5}$$

Für alle Datensätze mit der Zielklasse +1 ist also  $f(x) \geq +1$  (beziehungsweise analog für  $-1$ ). Die Grenzfälle der Gl. (5.4) und (5.5) beschreiben die beiden Hyperebenen  $H_1: f(x) = +1$  und  $H_2: f(x) = -1$ . Dabei besitzen beide Hyperebenen den gleichen Normalenvektor  $\mathbf{w}$  sowie den gleichen Abstand  $d_+$  beziehungsweise  $d_-$  zur trennenden Hyperebene. Anschaulich ausgedrückt sind beide parallel zur trennenden Hyperebene und es liegen keine Merkmalsvektoren  $\mathbf{x}_i$  dazwischen.

Die Abstandsreserve der trennenden Hyperebenen lässt sich über den Abstand der Hyperebenen  $H_1$  und  $H_2$  aus der Hesseschen Normalform bestimmen und beträgt  $2/\|\mathbf{w}\|$  [129, S. 45]. Gl. (5.4) und (5.5) lassen sich auch zusammenfassen zu:

$$y_i(\mathbf{x}_i\mathbf{w} + b) - 1 \geq 0 \quad \forall i. \quad (5.6)$$

Abb. 5.8 zeigt das beschriebene Vorgehen für den zweidimensionalen Fall. Die Hyperebenen werden hier zu Geraden. Die eingekreisten Datenpunkte entsprechen den Grenzfällen der Gl. (5.4) und (5.5) (beziehungsweise der Gleichheit von Ungleichung (5.6)). Sie definieren die Lage der Trenngerade und werden Stützvektoren (*engl.* support vectors) der SVM genannt.




Abb. 5.8 Lineare SVM mit separierbaren Daten [128, S. 129]

Um die Abstandsreserve  $2/\|\mathbf{w}\|$  zu maximieren, gilt es, die euklidische Norm des Normalenvektors  $\|\mathbf{w}\|$  unter der Bedingung von Gl. (5.6) zu minimieren. Diese Aufgabe stellt ein nichtlineares Optimierungsproblem mit Nebenbedingung dar und kann durch Minimierung der folgenden Lagrange-Funktion  $L_P$  mit den Lagrange-Multiplikatoren  $\alpha_i \geq 0$  erfolgen [128, S. 130]:

$$L_P = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_i \alpha_i (y_i(\mathbf{x}_i\mathbf{w} + b) - 1). \quad (5.7)$$

Wenn man die Ableitungen der Gl. (5.7) nach  $\mathbf{w}$  und  $b$  gleich 0 setzt, ergibt sich:

$$\mathbf{w} = \sum_i \alpha_i y_i \mathbf{x}_i, \quad (5.8)$$

$$\sum_i \alpha_i y_i = 0. \quad (5.9)$$

Beide Bedingungen werden nun wieder in Gl. (5.7) eingesetzt und liefern:

$$L_D = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j). \quad (5.10)$$

Nach Anwendung der Lagrange-Dualität lässt sich die Minimierung von  $L_p$  in eine Maximierung von  $L_D$  über  $\alpha_i$  umformen (Gl. (5.10)), wobei die Bedingung aus Gl. (5.9) erfüllt sein muss [128, S. 130-134]. Jeder Merkmalsvektor besitzt hierzu ein  $\alpha_i$ . Durch Anwendung der Karush-Kuhn-Trucker-Bedingungen als notwendige Optimalitätskriterien gilt  $\alpha_i > 0$  immer dann, wenn die Ungleichung (5.6) gleich 0 ist und damit der zugehörige Merkmalsvektor auch Stützvektor ist. Für die restlichen Merkmalsvektoren sind die  $\alpha_i = 0$ . Der optimale Normalenvektor  $\mathbf{w}$  ist damit eine Linearkombination von Stützvektoren, für die  $\alpha_i > 0$  gilt (Gl. (5.8)).

Der verbleibende Parameter  $b$  zur Definition der Hyperebene kann für einen beliebigen Stützvektor aus Gl. (5.6) ermittelt werden. Damit ist die Funktion  $f(\mathbf{x})$  vollständig bestimmt und lässt sich für einen ungesehenen Datensatz  $x$  auswerten. Das Vorzeichen des Funktionswertes, also  $\hat{y} = \text{sgn}(f(\mathbf{x}))$ , prädiziert die diskrete Klassenzugehörigkeit, der Funktionswert ein Wahrscheinlichkeitsmaß für die kontinuierliche Klassenzugehörigkeit.

Die Einführung einer Schlupfvariablen ermöglicht die Erweiterung des Vorgehens auf nicht-trennbare Datensätze [128, S. 134-136]. Damit müssen nicht mehr zwangsläufig alle Datensätze einer Klasse auf einer Seite der trennenden Hyperebene liegen. Die Gewichtung des Bestrafungsterms  $C$  bei einem auf der falschen Seite liegenden Datensatz kommt als Modellparameter dazu und kann vom Anwender eingestellt werden. Je größer  $C$  gewählt ist, desto größer ist die Bestrafung.

### Nichtlineare SVM

Oft ist die gesuchte Trennebene in einem Datensatz nichtlinearer Natur und selbst die Erweiterung auf einen tolerierten Fehler nicht zweckmäßig [128, S. 137-138]. Um die lineare SVM in eine nichtlineare SVM umzuwandeln, wendet man folgende, auch als „Kernel-Trick“ bezeichnete Methode an [124, S. 347]. Im ersten Schritt werden die Merkmalsvektoren  $\mathbf{x}_i$  mit Hilfe der Abbildung  $\Phi$  in einen höherdimensionalen Raum  $\mathcal{H}$  projiziert:

$$\Phi: \mathbb{R}^q \rightarrow \mathcal{H}. \quad (5.11)$$

Die Trainingsdaten in der zu maximierenden Funktion  $L_D$  aus Gl. (5.10) treten nur als Skalarprodukt  $\mathbf{x}_i \cdot \mathbf{x}_j$  auf und können durch das Skalarprodukt  $\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$  ersetzt werden. Findet man eine Kernelfunktion  $K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$ , dann kommt überall im Algorithmus anstatt des Skalarprodukts  $\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$  nur  $K$  vor.  $\Phi$  muss dann nicht mehr explizit bekannt sein. Die am häufigsten genutzte Kernelfunktion ist die radiale Basisfunktion RBF und wird auch in dieser Arbeit eingesetzt:

$$K(\mathbf{x}_i, \mathbf{x}_j) = e^{-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2}. \quad (5.12)$$

Der Kernelparameter  $\sigma$  ist einstellbar und kann das Modell parametrieren. Durch den Kernel-Trick gelten alle linearen SVM-Ansätze nach wie vor. Die weiterhin lineare Trennung findet



jedoch in einem höherdimensionalen Raum  $\mathcal{H}$  statt. Wird  $\mathbf{w}$  aus Gl. (5.8) in die Auswertefunktion  $f(\mathbf{x})$  eingesetzt, erhält man

$$f(\mathbf{x}) = \sum_i \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (5.13)$$

und kann analog die Klassenzugehörigkeit eines neuen Datensatzes  $\mathbf{x}$  über das Vorzeichen des Funktionswertes von  $f(\mathbf{x})$  bestimmen.

### Eigenschaften

Die Support Vector Machine erzeugt eine optimale Entscheidungsfunktion für eine Prädiktionsaufgabe [128, S. 142-145]. Die Lösung der zu Grunde liegenden Optimierungsaufgabe führt immer zu einer optimalen Entscheidungsfunktion, weil die konvexe Kostenfunktion  $L_D$  keine lokalen Minima besitzt. Einen großen Einfluss hat dabei die Kernelfunktion. Sie bestimmt, wie flexibel die Hyperebene den Datensatz trennen kann [124, S. 347]. Neben der RBF kommen häufig polynomiale oder sigmoidale Funktionstypen zum Einsatz. Zudem kann a-priori Wissen zur Problemstellung in die Gestaltung der Kernelfunktion einfließen [127, S. 285]. Neben der Parametrierung der Kernelfunktionen selbst, wie am Beispiel der RBF mit dem  $\sigma$  gezeigt, kommt lediglich der Gewichtungswert  $C$  als Einstellparameter der Entscheidungsfunktion hinzu. Damit ist es möglich, das Verhalten des Lernmodells bezüglich Unter- oder Überanpassung zu verändern, was zudem die Performance beeinflusst.

Die Leistungsfähigkeit der SVM ist verglichen zu anderen Methoden immer abhängig vom Anwendungsfall [124, S. 350]. Aufgrund des Optimierungsansatzes besitzt die SVM jedoch eine deutlich bessere Performance als der einfache Entscheidungsbaum [116, S. 351]. In einigen Disziplinen wie der Objekterkennung, der Erkennung handschriftlicher Ziffern oder der Gesichtserkennung liefert die SVM sehr gute Ergebnisse [128, S. 121-122]. Obwohl die SVM ursprünglich als binärer Klassifikator entwickelt wurde, ist eine Erweiterung für eine Klassifikation mit  $n$  Klassen durch  $n$  Modelle möglich [128, S. 143]. Nach dem Prinzip „einer gegen alle“ erfasst dabei jedes Einzelmodell eine einzelne Klasse als +1, den restlichen Klassen wird der Wert  $-1$  zugeordnet.

Nachteilig an der SVM sind vor allem der hohe Rechenaufwand und der benötigte Speicherbedarf während des Trainingsprozesses [128, S. 157]. Für große Datensätze mit Millionen von Stützvektoren kann der Algorithmus wegen des hohen Speicherbedarfs nicht mehr gelöst werden. Ein weiterer Nachteil ist die Empfindlichkeit gegenüber Merkmalsskalierung und unwichtigen Merkmalen [124, S. 349]. In der Anwendung gilt daher sowohl eine Normierung als auch eine Auswahl der Merkmale als wichtig. Für mehr Details zur Methode sei auf [128] und [127] verwiesen.

### 5.3.2 Verwendete Datensatzkombinationen

Die dem Lernalgorithmus übergebenen Datensätze werden über zwei Verfahren ausgewählt. Zunächst ermöglicht die Eventvariable Pre-Incident Manöver eine Aufteilung in sinnvolle, zu untersuchende Datensatzgruppen. Anschließend erfolgt die für Lernverfahren nötige Trennung in Trainings- und Testdaten mit Hilfe der  $k$ -fachen Kreuzvalidierung.

## Datensatzaufteilung über Eventvariablen

Grundsätzlich kommen Unfälle in der Realität so selten vor, dass die wirklichen Verhältnisse auf die Häufigkeiten der Baseline- und Unfalldatensätze nicht übertragbar sind. Das bereits reduzierte Datenpaket aus der Datenvorverarbeitung in Kap. 5.2 enthält zwar insgesamt 19.600 Baseline- und 840 Unfalldatensätze. Bei als durchschnittlich angenommenen Unfallhäufigkeiten wären trotzdem noch mehr Baseline-Fälle zur Abbildung der Realität nötig. Der Unterschied müsste sich dafür jedoch um Größenordnungen unterscheiden: Die Verunglücktenzeitrate kann grob mit 3 pro  $10^5$  Stunden Verkehrsbeteiligung für den motorisierten Individualverkehr abgeschätzt werden [130, S. 50]. Eine Datenaufzeichnung mit 30 s Sequenzen würde damit durchschnittlich für jeden Unfall mit einem Verunglückten  $4 \cdot 10^6$  Baseline-Fälle benötigen. Die verwendeten Unfallschweretypen der Studie kämen damit für jeden Unfalldatensatz auf etwa  $10^4 - 10^5$  Baselinedatensätze [1, S. 6][26, S. 26].

Eine Einteilung der Datensätze erfolgt über die kategorische Eventvariable „Manöver vor dem Ereignis“ (Pre-Incident Manöver), die das Fahrmanöver 2 bis 6 Sekunden vor dem Ereignis enthält [96, S. 11]. Der Einteilung in Manöverkategorien liegt zugrunde, dass Maschinenlernverfahren aufgrund ihrer Funktionsweise am ehesten Muster und Gesetzmäßigkeiten in vielen ähnlichen Beispieldatensätzen erkennen. Es werden daher gleichartige Manöverkategorien zu Datensatzkombinationen zusammengefasst. Damit ist zu erwarten, dass die erzeugten Merkmale innerhalb einer Gruppe vergleichbar und damit gut analysierbar sind.

Es werden nur Datensätze weiterverwendet, in denen die Kategorie aus der Variable „Manöver vor dem Ereignis“ mindestens so viele Baseline- wie Unfalldatensätze enthält. Das bewirkt eine realistischere Datensatzzusammenstellung. Dem Maschinenlernprozess sollen damit ausreichend viele Pre-Incident Manöverarten von sowohl Unfall- als auch Baseline-Fällen übergeben werden. Tabelle 5.4 fasst diese Kategorien zusammen.

Tabelle 5.4 Kategorien der Eventvariable Pre-Incident Manöver mit mehr Baseline- als Unfalldatensätzen

Geradeausfahrt	Kurvenfahrt	Sonstige
Verzögerung auf Fahrstreifen	Links-Abbiegen	Fahrstreifenwechsel
Geradeausfahrt mit Beschleunigung	Rechts-Abbiegen	Einfahren in Parkposition
Geradeausfahrt mit unbeabsichtigtem Drift	Kurvenfahrt	Durchführung einer Kehrtwendung
Geradeausfahrt mit konstanter Geschwindigkeit		Ausweichen auf Fußgänger/Radfahrer
		Ausweichen auf Fahrzeug
		Ausweichen auf Objekt
		Einfädelmanöver
		Überholmanöver

In Tabelle 5.5 sind mögliche Datensatzkombinationen dargestellt. Die Datensatzkombination „Geradeausfahrt“ enthält verschiedene Situationen des Längsverkehrs. Hierbei sind die Pre-Incident Manöverarten „Verzögerung auf Fahrstreifen“, „Geradeausfahrt mit Beschleunigung“, „Geradeausfahrt mit unbeabsichtigtem Drift“ und „Geradeausfahrt mit konstanter Geschwindigkeit“ zusammengefasst.

Tabelle 5.5 Übersicht zu möglichen Datensatzkombinationen nach [113, S. 41]

Datensatzkombination	Anzahl an Unfall-Datensätzen	Anzahl an Baseline-Datensätzen
Geradeausfahrt	~365	~15.600
Kurvenfahrt	~75	~3.000
Fahrten mit Radardaten	~540	~13.900
Alle Datensätze	~740	~19.600

Die Datensatzkombination „Kurvenfahrt“ enthält die Manöverarten „Links-Abbiegen“, „Rechts-Abbiegen“ und „Kurvenfahrt“. Diese Gruppe fokussiert sich daher auf Fälle mit einer gewissen Querdynamik. Überdies zeigt sich, dass ein Großteil der Unfälle nicht ausreichend durch das verwendete Sensorset aufgezeichnet beziehungsweise die Unfallschwere falsch bezeichnet wurde. Zum einen liegen Fälle vor, die trotz Frontkollision in der Kurve kein Radarobjekt enthielten. Der beschränkte Öffnungswinkel des verwendeten Radarsensors ist hier vermutlich die Ursache. Zum anderen wurden viele Bordsteinrempler oder Fälle mit leichtem, kurzfristigem Abkommen von der Fahrbahn nicht in die geringste und damit eigentlich bereits aussortierte Unfallschwere-Kategorie eingeordnet. Angesprochene Fälle werden daher manuell per Videoanalyse identifiziert und aus der Datensatzkombination „Kurvenfahrt“ ausgeschlossen (Anhang A 5.3.2). Es bleiben somit noch ca. 75 Unfälle sowie 3.000 Baseline-Fälle übrig.

Als dritte Datensatzkombination sind die Fahrten mit mindestens einem auftauchenden Radarobjekt aufgeführt. Die Motivation liegt darin, den Einfluss der Radarsignale besser analysieren zu können. Wie jedoch bereits in „Kurvenfahrt“ skizziert, erweisen sich die enthaltenen Umfeldinformationen des Radarsensors als unzuverlässig. Deshalb wird diese Datensatzkombination nicht weiterverwendet. Die letzte Gruppe fasst alle Datensätze mit den Kategorien aus Tabelle 5.4 zusammen.

Die folgenden Auswertungen werden daher hauptsächlich für die beiden Datensatzkombinationen Geradeausfahrt und Kurvenfahrt durchgeführt. Bedingt durch die manuelle Auswertung der ungeeigneten Fälle ergibt sich eine relativ geringe Anzahl an Unfalldatensätzen bei Kurvenfahrt. Diese sollen aus zwei Gründen trotz der ungünstigen Fallanzahl beibehalten werden. Zum einen wurden in bisherigen Untersuchungen häufig nur Unfallursachen im Längsverkehr analysiert [35][41][76][77][81][82]. Zum anderen sollen für die Kritikalitätsschätzung während der Kurvenfahrt besonders auch die langsam veränderlichen Kritikalitätsmaße wie reibwertmindernde Umstände in den Schätzprozess miteinbezogen werden.

Es wird angenommen, dass das aktuell gefahrene Manöver während einer Fahrt identifizierbar und klassifizierbar ist. Für eine kontinuierliche Zeitreihenklassifikation online im Fahrzeug könnte für beide Manövervarianten die jeweilige Auswertelogik getriggert ablaufen.

### **Datensatzaufteilung mit $k$ -facher Kreuzvalidierung**

Die Anwendung maschineller Lernmethoden besteht immer aus einer Anlern- und einer Validierungsphase. Dazu müssen die zur Verfügung stehenden Datensätze in Trainingsdatensätze zum Anlernen und Testdatensätze zur Validierung aufgeteilt werden. Die Informationen eines Datensatzes stehen somit entweder für den Trainingsprozess oder für den Validierungsprozess zur Verfügung [116, S. 241-249]. Bei umfangreichen Datensätzen reicht dieser Ansatz aus. In der Realität ist die Generierung der Datensätze häufig ein aufwändiger Prozess und damit die Anzahl der Datensätze begrenzt. Deshalb ist es erstrebenswert, möglichst alle Datensätze sowohl beim Trainings- als auch beim Validierungsprozess zu verwenden.

Die am häufigsten genutzte Methode dieses Ziel zu erreichen, stellt die  $k$ -fache Kreuzvalidierung (*engl.*  $k$ -fold cross-validation) dar [116, S. 241-249]. Hier werden in einem ersten Schritt alle Datensätze in  $k$  nach Möglichkeit gleich große Teilmengen aufgeteilt. Anschließend werden in  $k$  Testdurchläufen insgesamt  $k$  Lernermodelle erzeugt, wobei in jeder Iteration eine andere Teilmenge der Validierung dient. Aus den restlichen  $k - 1$  Teilmengen wird je Iteration

das Modell angelernt. Das beispielhafte Vorgehen für eine 4-fache Kreuzvalidierung zeigt Abb. 5.9.




Abb. 5.9 Schematisches Vorgehen einer 4-fachen Kreuzvalidierung nach [113, S. 23]

Um die Güte des maschinellen Lernverfahrens bestimmen zu können, bedarf es der Kombination der Bewertungsgrößen (Kap. 5.3.6) der einzelnen Lernermodelle. Für absolute Größen kann dies durch Kumulierung, bei relativen Größen durch Mittelwertbildung über alle einzelnen Bewertungsgrößen erfolgen. Die Anwendung der  $k$ -fachen Kreuzvalidierung ist daher denkbar einfach. Alle Teildatensätze werden genau einmal bei der Auswertung berücksichtigt, ab  $k > 2$  wird die Mehrheit der Datensätze zum Anlernen verwendet. Es gilt zu beachten, dass das Ziel des Verfahrens die vollständige Ausnutzung des Datensatzes ist. Die damit erzeugten Ergebnisse werden aussagekräftiger. Das Verfahren hat nicht zum Ziel, die  $k$  Lernermodelle wieder zu einem Modell zusammenzufassen.

Die  $k$ -fache Kreuzvalidierung besitzt nur den Einstellparameter  $k$ . Weil dieser nur geringen Einfluss auf das Klassifikationsergebnis hat, wird er fest auf  $k = 10$  gesetzt. Der Wert 10 stellt hierbei einen guten Kompromiss zwischen Bias- und Varianzfehler dar [116, S. 243]. Somit wird bei akzeptablem Rechenaufwand die Klassifikationsgüte hinreichend genau bestimmt.

### 5.3.3 Erzeugung von entscheidungsrelevanten Merkmalen

Die Erzeugung von entscheidungsrelevanten Merkmalen wird in vier Gruppen durchgeführt. Die erste Gruppe erstellt Merkmale aus fahrzeugkinematischen Signalen über standardisierte mathematische Methoden. Eine weitere generiert wissensbasierte Merkmale des Fahrzeugumfeldes aus den Radarsensordaten. Darüber hinaus werden Merkmale über die Integration der langsam veränderlichen Kritikalitätsmaße erzeugt. Abschließend erfolgt die Erstellung von kombinierten Merkmalen aus mehreren der genannten Gruppen.

Die Erzeugung von Merkmalen aus Zeitreihensignalen bezieht sich immer auf ein definiertes, zugrunde liegendes Zeitfenster der Datensequenz. Die variablen Parameter sind hier Zeitfensterlänge und Zeitfensterende vor dem Ereignis (Abb. 5.10). Der Ereigniszeitpunkt kennzeichnet bei Unfalldatensätzen den Aufprallzeitpunkt, bei Baseline-Datensätzen den Zeitpunkt 1 s vor Sequenzende.

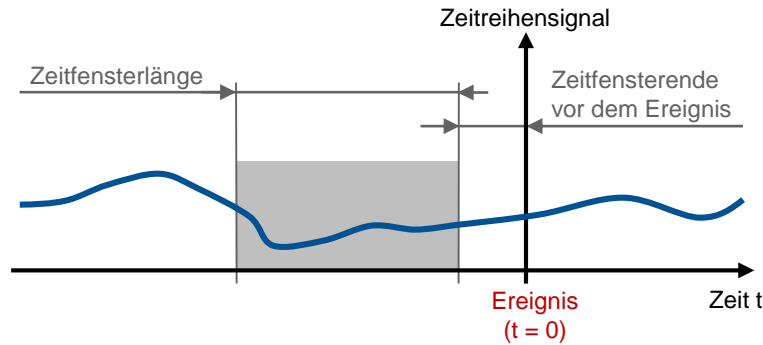


Abb. 5.10 Parametrierung des Zeitfensters zur Erzeugung von Merkmalen aus Zeitreihendaten nach [113, S. 42]

## Merkmale aus fahrzeugkinematischen Signalen

Die Erzeugung standardisierter Zeitreihenmerkmale erfolgt aus den permanent vorhandenen fahrzeugkinematischen Signalen  $v$ ,  $\dot{\psi}$ ,  $a_x$ ,  $a_y$  und  $a_z$ . Die verwendeten Methoden fasst Tabelle 5.6 zusammen. Die Signale beinhalten die gängigen Zustandsgrößen zur Beschreibung der Fahrzeugkinematik. Mit statistischen Merkmalen wird die Verteilung der Zeitreihendaten genutzt, um eine Aussage zur Zielgröße zu erhalten. Als Lagemaß wird der arithmetische Mittelwert (*mean*) herangezogen [75, S.66, S.87]. Als Streumaße werden die Standardabweichung (*std*), die mittlere absolute Abweichung vom Medianwert (*mad*) sowie der Interquartilabstand (*iqr*) eingesetzt [75, S.66, S.80, S.89].

Tabelle 5.6 Erzeugung von Merkmalen aus fahrzeugkinematischen Signalen mit standardisierten Methoden nach [113, S. 42]

Signal	Statistische Merkmale	Extremwerte	Diskrete Fouriertransformation
$v$ in km/h	std, mean, mad, iqr	min, max	0Hz-0,3Hz, 0,3Hz-1Hz, 0Hz-1Hz, 1Hz-3Hz, 3Hz-5Hz
$\dot{\psi}$ in °/s	std, mean*, mad*, iqr*	min*, max*	0Hz-1Hz, 1Hz-3Hz, 3Hz-5Hz
$a_x$ in g	std, mean, mad, iqr	min, max	0Hz-1Hz, 1Hz-3Hz, 3Hz-5Hz
$a_y$ in g	std, mean*, mad*, iqr*	min*, max*	0Hz-1Hz, 1Hz-3Hz, 3Hz-5Hz
$a_z$ in g	std, mean, mad, iqr	min, max	0Hz-1Hz, 1Hz-3Hz, 3Hz-5Hz

\* Für diese Merkmale wurden die Zeitreihenwerte betragsmäßig verwendet

Besonders in Anwendungen, bei denen das Unter-/Überschreiten von Schwellwerten eine Aussage zur Zielgröße liefern kann, werden die Extremwerte einer Zeitreihe als Merkmal mitverwendet [131, S. 97]. Deshalb erfolgt die Bildung von sowohl Minima als auch Maxima der Signale. Aufgrund der großen Rauschanfälligkeit muss dazu das Ursprungssignal ausreichend gefiltert sein.

Eine weitere Möglichkeit zur Erstellung von Merkmalen basiert auf den Frequenzeigenschaften des Signals [131, S. 95-96]. Die diskrete Fouriertransformation (FFT) kann ohne a-priori Wissen die Ausprägung dominanter Frequenzbereiche sichtbar machen. Die Grenzen der jeweiligen Frequenzbereiche sind in der Tabelle aufgeführt. Das Ergebnis wird ebenso als Merkmal verwendet.

Zusätzlich wird der aktuell befahrene Kurskrümmungsradius  $R$  aus den Signalen  $v$  und  $\dot{\psi}$  berechnet [132, S. 868] und daraus folgende Merkmale gebildet:

- Mittelwert des Betrags des Kurskrümmungsradius:  $\text{mean}(\text{abs}(R))$
- Standardabweichung des Betrags des Kurskrümmungsradius:  $\text{std}(\text{abs}(R))$

## Merkmale aus Radarsensordaten

Im Gegensatz zu fahrzeugkinematischen Signalen liegen Radarinformationen nur vor, wenn auch Objekte detektiert wurden. Folglich blieben viele erzeugte Merkmale undefiniert, was sich auf ein maschinelles Lernverfahren negativ auswirkt. Aus diesem Grund werden wissensbasierte Merkmale modelliert, die ein robusteres Verhalten gegenüber fehlenden Werten vorweisen. Tabelle 5.7 zeigt alle erzeugten, wissensbasierten Merkmale aus den Radarsensordaten.

Die Merkmale basieren auf der Distanz, Zeitlücke, TTC (*Time-To-Collision*), Lage oder Beschleunigung von detektierten Objekten. Neben den im vorherigen Abschnitt bereits genutzten Kennzahlen Mittelwert, Standardabweichung und Extremwert wird zur Modellierung der wissensbasierten Merkmale zusätzlich die Inverse verwendet. Das ist besonders bei unregelmäßig verfügbaren oder oft gegen unendlich strebenden Größen wie der Zeitlücke, der TTC und der Distanz vorteilhaft. Bei vorliegenden Objekten erstreckt sich damit der Wertebereich von Werten nahe 0 für eine unkritische Umgebung bis hin zu einem definierbaren oberen Schwellwert für kritische Situationen. Bei keinen detektierten Objekten kann so der unkritische Wert 0 verwendet werden.

Tabelle 5.7 Wissensbasierte Erzeugung von Merkmalen aus Radarsensordaten nach [113, S. 42]

Beschreibung der wissensbasierten Größe	Abgeleitete Merkmale
Distanz zum nächsten Objekt	<ul style="list-style-type: none"> <li>• Inverse: <math>\text{inv}(\text{mindist})</math></li> <li>• Mittelwert der Inverse: <math>\text{mean}(\text{inv}(\text{mindist}))</math></li> <li>• Standardabweichung der Inverse: <math>\text{std}(\text{inv}(\text{mindist}))</math></li> <li>• Maximum der Inverse <math>\text{max}(\text{inv}(\text{mindist}))</math></li> </ul>
Anzahl Objekte	<ul style="list-style-type: none"> <li>• bis Öffnungswinkel 24°: <math>\text{num\_obj\_front}^*</math></li> <li>• bis Öffnungswinkel 60°: <math>\text{num\_obj\_frontseite}^*</math></li> <li>• ab Öffnungswinkel 60°: <math>\text{num\_obj\_seite}^*</math></li> <li>• mit gleicher Bewegungsrichtung: <math>\text{num\_obj\_paral}^*</math></li> <li>• mit entgegengesetzter Bewegungsrichtung: <math>\text{num\_obj\_antiparal}^*</math></li> <li>• ruhend: <math>\text{num\_obj\_stat}^*</math></li> <li>• auf gleichem Fahrstreifen: <math>\text{num\_obj\_gleicherFS}^*</math></li> <li>• gesamt: <math>\text{num\_obj\_ges}^*</math></li> </ul>
Vorhandensein eines Vorderfahrzeugs im gesamten Zeitfenster	<ul style="list-style-type: none"> <li>• <math>\text{exist\_VorderFahrzeug}</math></li> </ul>
TTC von Objekten in gleicher Fahrtrichtung	<ul style="list-style-type: none"> <li>• Inverse der minimalen TTC: <math>\text{inv}(\min(\text{TTC\_obj\_Dir})^*)</math></li> <li>• Maximum der Inverse der minimalen TTC: <math>\text{max}(\text{inv}(\min(\text{TTC\_obj\_Dir}))</math></li> </ul>
TTC zum Vorderfahrzeug	<ul style="list-style-type: none"> <li>• Inverse: <math>\text{inv}(\text{TTC\_Vorderfahrzeug}^*)</math></li> <li>• Mittelwert der Inverse: <math>\text{mean}(\text{inv}(\text{TTC\_Vorderfahrzeug}))</math></li> <li>• Standardabweichung der Inverse: <math>\text{std}(\text{inv}(\text{TTC\_Vorderfahrzeug}))</math></li> </ul>
TTC zum Vorderfahrzeug mit Berücksichtigung der Relativbeschleunigung [132, S. 899-902]	<ul style="list-style-type: none"> <li>• Minimum: <math>\min(\text{aTTC\_Vorderfahrzeug})</math></li> <li>• Mittelwert: <math>\text{mean}(\text{aTTC\_Vorderfahrzeug})</math></li> </ul>
Zeitlücke THW zum Vorderfahrzeug	<ul style="list-style-type: none"> <li>• Inverse: <math>\text{inv}(\text{THW\_Vorderfahrzeug}^*)</math></li> <li>• Mittelwert der Inverse: <math>\text{mean}(\text{inv}(\text{THW\_Vorderfahrzeug}))</math></li> <li>• Standardabweichung der Inverse: <math>\text{std}(\text{inv}(\text{THW\_Vorderfahrzeug}))</math></li> </ul>
Absolute Beschleunigung des Vorderfahrzeugs in x-Richtung von Ego	<ul style="list-style-type: none"> <li>• <math>\text{a\_abs\_Vorderfahrzeug}^*</math></li> <li>• Mittelwert: <math>\text{mean}(\text{a\_abs\_Vorderfahrzeug})</math></li> <li>• Standardabweichung: <math>\text{std}(\text{a\_abs\_Vorderfahrzeug})</math></li> </ul>
Relative Distanzreserve zum Vorderfahrzeug für Ausweich- oder Bremsmanöver [132, S. 899]	<ul style="list-style-type: none"> <li>• Minimum: <math>\min(\text{dist\_rel\_res\_Vorderfahrzeug})</math></li> <li>• Mittelwert: <math>\text{mean}(\text{dist\_rel\_res\_Vorderfahrzeug})</math></li> </ul>

\*Abbildung über Berücksichtigung eines Vergessensfaktors

Zusätzlich sind einige Größen über einen Vergessensfaktor abgebildet. Die einzelnen Werte des zugrunde liegenden Zeitfensters werden gewichtet aufsummiert und anschließend über der Summe der Gewichtungsfaktoren normiert. Der exponentiell ansteigende Gewichtungsfaktor betont die aktuelleren, nahe dem Zeitfensterende liegenden Werte (Abb. 5.11).

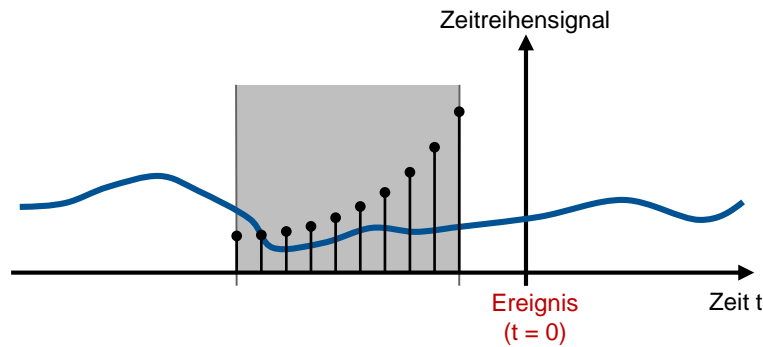


Abb. 5.11 Gewichtung der Zeitreihenwerte eines Zeitfensters mit einem Vergessensfaktor nach [113, S. 43]

Es sei angemerkt, dass hier ebenso die in Abschnitt 2.1.3 vorgestellten Kritikalitätsmaße als Merkmale verwendet werden könnten. Dazu wäre aber ein genaueres Umgebungsabbild nötig gewesen, als es die vorliegenden SHRP2 Daten aufweisen.

## Merkmale aus langsam veränderlichen Kritikalitätsmaßen

Die langsam veränderlichen Kritikalitätsmaße aus Kapitel 4 stellen Faktoren auf eine Unfallwahrscheinlichkeit dar. Der Einfluss wird durch das für jede Kategorie berechnete Odds Ratio quantifiziert. Die für jede Eventvariable am häufigsten vorkommende Kategorie wurde als neutrale Kategorie gewählt und hat den Wert 1. Wenn man für jede Variable ein eigenes Merkmal erzeugen würde, ergäbe sich damit eine geringe Aussagekraft des Merkmals bezüglich der Klassifikationsaufgabe. Deshalb werden die Eventvariablen zu Gruppen zusammengefasst. Diese Gruppen stellen dann die Merkmale dar. Die Verrechnung der Odds Ratio  $OR_i$  aller in einer Gruppe enthaltenen Kategorien erfolgt über:

$$\tilde{x}_{OR} = \log \left( \prod_i OR_i \right). \quad (5.14)$$

Da dieses Merkmal seltener den neutralen Wert  $\log(1) = 0$  annimmt, lassen sich damit die Datensätze besser trennen. Die Einteilung der 19 Eventvariablen in Merkmale zeigt Abb. 5.12.

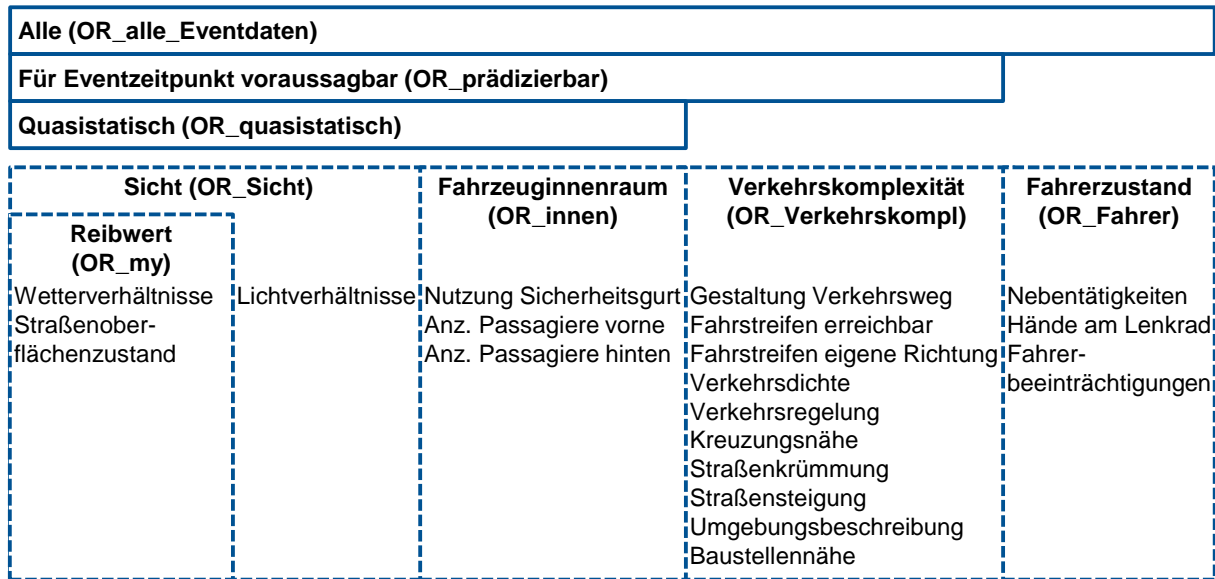


Abb. 5.12 Gruppierung der langsam veränderlichen Kritikalitätsmaße in Merkmale nach [113, S. 46]

Es gibt drei Gruppen, die versuchen, alle Kritikalitätsmaße zu vereinen. Jede Gruppe besitzt eine unterschiedliche Verfügbarkeit während einer möglichen Online-Auswertung im Fahrzeug. Die quasistatische Gruppe enthält mit den Einflüssen aus Wetter, Straßenoberfläche, der Sicht und des Fahrzeuginnenraums Informationen, die über längere Zeiträume von mehr als 60s im Voraus bestimmbar sind. Die weiteren Variablengruppen Verkehrskomplexität und Fahrerzustand beziehen sich in den vorliegenden Daten immer auf den Ereigniszeitpunkt. Da sich die Verkehrsumgebung mithilfe dynamischer und genauer Navigationsdaten für Zeiträume von bis zu 20s und damit für den Eventzeitpunkt präzisieren lässt, wird diese Gruppe ins Merkmal OR\_prädizierbar integriert. Der aktuelle Fahrerzustand verändert sich im Vergleich zu den anderen Variablen am schnellsten. Eine Prädiktion der Handlungen, beispielsweise der Nebentätigkeiten, über mehrere Sekunden scheint schwierig, wohingegen die Bestimmung des aktuellen Zustandes schon möglich ist. Mit diesem Verständnis der Verfügbarkeit wird der Fahrerzustand im Merkmal OR\_alle\_Eventdaten vereint.

Im späteren Lernprozess wird immer nur eine der Gruppen als Merkmal verwendet. Durch diese Variation lässt sich der Einfluss der Auswahl auf die Klassifikationsgüte analysieren (Kap. 5.4.1).

## Kombinierte Merkmale verschiedener Kategorien

Es lassen sich auch aus verschiedenen Kategorien kombinierte Merkmale erzeugen (Tabelle 5.8). Diese zielen darauf ab, mögliche physikalische oder logische Zusammenhänge für die Zeiträume vor einem Unfall abzubilden. Die Verknüpfung eines reduzierten Kraftschlussbeiwertes mit einem longitudinalen oder lateralen Manöver erfolgt beispielsweise durch die Kombination des Reibwert-Merkmals OR\_my mit fahrzeugkinematischen Merkmalen. Dieser physikalische Zusammenhang bedeutet für das Fahrzeug eine eingeschränkte Manövrierfähigkeit. Die Anwendung der Exponentialfunktion wird hier mit exp bezeichnet. Des Weiteren zielt die Kombination aus einem bevorstehenden Frontunfall und dem Fahrerzustandsmerkmal auf die möglicherweise durch Nebentätigkeiten oder Fahrerbeeinträchtigungen bedingte, eingeschränkte Reaktionsfähigkeit ab. Eine ähnliche logische Verknüpfung von kritischer vorderer Fahrzeugumgebung und Umgebungskomplexität soll schwierig beherrschbare und



unter komplexen Bedingungen stattfindende Situationen als Merkmal für den Klassifikationsansatz sichtbar und nutzbar machen.

Tabelle 5.8 Erzeugung von kombinierten Merkmalen verschiedener Kategorien nach [113, S. 46]

Kombination	Beschreibung	Abgeleitetes Merkmal
Reibwert und fahrzeug-kinematische Merkmale	Multiplikation von $\text{mean}(v)$ und $\text{exp}(\text{OR\_my})$	$\text{mean}(v)\_OR\_my$
	Multiplikation von $\text{mean}(a_x)$ und $\text{exp}(\text{OR\_my})$	$\text{mean}(a_x)\_OR\_my$
	Multiplikation von $\text{std}(a_x)$ und $\text{exp}(\text{OR\_my})$	$\text{std}(a_x)\_OR\_my$
	Multiplikation von $\text{std}(\text{abs}(a_y))$ und $\text{exp}(\text{OR\_my})$	$\text{mean}(\text{abs}(a_y))\_OR\_my$
	Multiplikation von $\text{std}(a_y)$ und $\text{exp}(\text{OR\_my})$	$\text{std}(a_y)\_OR\_my$
Vordere Fahrzeugumgebung und Fahrerzustand	Addition von $\text{max}(\text{inv}(\text{min}(\text{TTC\_obj\_Dir})))$ und $\text{OR\_Fahrer}$	$\text{TTC\_OR\_Fahrer}$
Vordere Fahrzeugumgebung und Umgebungskomplexität	Addition von $\text{max}(\text{inv}(\text{min}(\text{TTC\_obj\_Dir})))$ und $\text{OR\_Verkehrskompl}$	$\text{TTC\_OR\_Verkehrskompl}$

### 5.3.4 Merkmalsauswahl

Die Merkmalsauswahl bestimmt aus allen erzeugten  $p$  Merkmalen  $\tilde{x}$  eine Untermenge an  $q$  besonders relevanten Merkmalen  $x$ :

$$f: \mathbb{R}^p \rightarrow \mathbb{R}^q, \quad \tilde{x} \rightarrow x. \quad (5.15)$$

Die Verfahren zur Merkmalsauswahl reduzieren lediglich die Anzahl der Merkmale, die Merkmalsausprägungen bleiben unverändert. Durch die Fokussierung auf relevante Merkmale erhöht sich einerseits das Systemverständnis und verringert andererseits den Rechenaufwand für Maschinenlernalgorithmen sowie den Speicherbedarf einzelner Datensätze [133, S. 1158]. Den Ausgangspunkt dieses Abschnitts stellt ein Stand der Wissenschaft mit einem Überblick zur Einordnung und Wirkungsweise von Methoden zur Merkmalsauswahl dar. Anschließend erfolgen eine Diskussion bezüglich des vorliegenden Anwendungsfalls und die Beschreibung des gewählten Vorgehens.

#### Stand der Wissenschaft: Merkmalsauswahl

Die Verfahren zur Merkmalsauswahl lassen sich in Filter-, Wrapper- und Embedded-Methoden einteilen [133, S. 1166-1167]. Einen Überblick zur Funktionsweise dieser Methoden gibt Abb. 5.13.

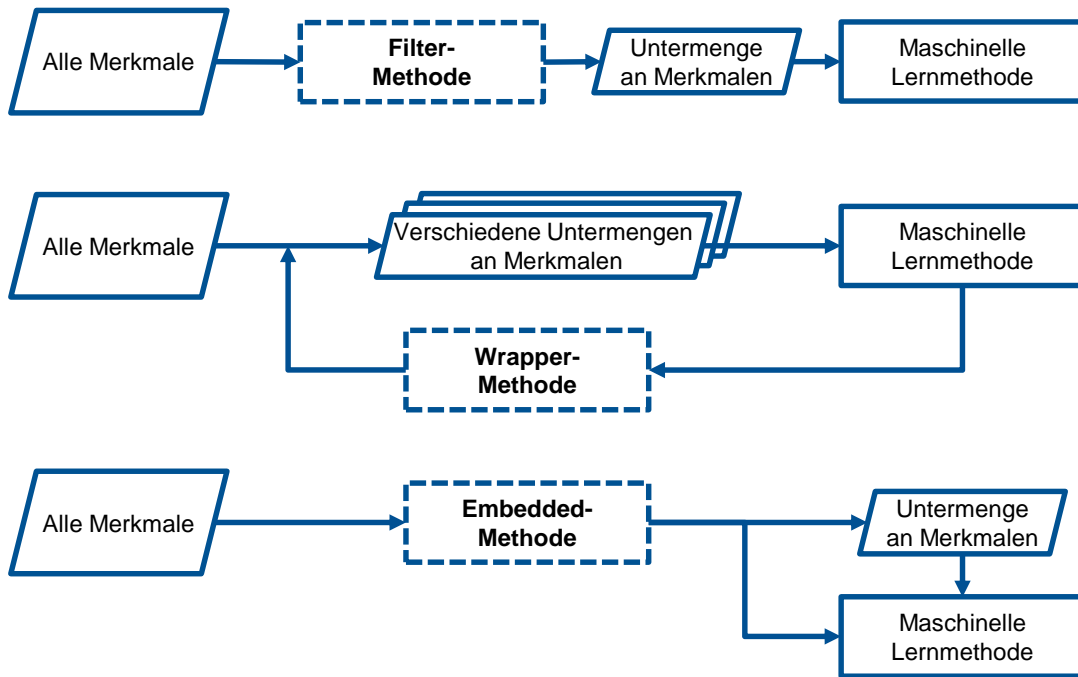


Abb. 5.13 Überblick zur Funktionsweise von Verfahren zur Merkmalsauswahl nach [134, S. 15]

Die Filter-Methode ist dem Trainingsprozess vorgelagert und wählt daher die wichtigsten Merkmale unabhängig vom maschinellen Lernalgorithmus aus. Zuerst wird über ein Maß der direkte Zusammenhang zwischen einzelnen Merkmalen und der Zielgröße bestimmt [135]. Daraus bestimmt die Methode direkt die relevanten Merkmale. Der Pearson-Korrelationskoeffizient ist hier ein häufig genutztes Maß für Regressions- und binäre Klassifikationsaufgaben [133, S. 1160-1161]:

$$R_i = \frac{Cov(X_i, Y)}{\sqrt{Var(X_i) Var(Y)}} . \quad (5.16)$$

Der Korrelationskoeffizient  $R_i$  zeigt die Korrelation des  $i$ -ten Merkmals mit den Merkmalsausprägungen  $X_i$  auf die Zielgrößen der einzelnen Datensätze  $Y$  an.  $Cov$  und  $Var$  bezeichnen die stochastischen Maße Kovarianz und Varianz. Je größer der Koeffizient des Merkmals, desto besser können Rückschlüsse vom Merkmal auf die Zielgröße gezogen werden. Da für jedes Merkmal nur ein Maß berechnet werden muss, gilt die Filter-Methode als wenig rechenaufwändig [135, S. II]. Interaktionen zwischen Merkmalen können indessen nicht berücksichtigt werden.

Die Wrapper-Methode integriert den maschinellen Lernprozess in die Merkmalsauswahl [135, S. II]. Für verschiedene Untermengen von Merkmalen wird hierzu die Lernmethode ausgewertet. Eine Bewertungsgröße der Schätzgüte (Kap. 5.3.6) gibt Aufschluss über die Qualität der Merkmalsauswahl. Weil eine Auswertung aller möglichen Merkmalskombinationen rechenaufwändig ist, nutzt man verschiedene Suchalgorithmen wie beispielsweise die Vorwärtsselektion (Abb. 5.14). Bei dieser wird zuerst das Merkmal bestimmt, das nach Auswertung im Lernalgorithmus die beste Schätzgüte vorweist. Anschließend kombiniert man dieses erste Merkmal mit allen verbleibenden Merkmalen, um die beste Kombination zu finden. Auf diese Weise werden für jede Iteration weitere Merkmale hinzugefügt. Die Untermenge an Merkmalen mit der besten Schätzgüte über alle Kombinationen wird schließlich ausgewählt.




Abb. 5.14 Schematische Funktionsweise der Wrapper-Methode mit Vorwärtsselektion nach [113, S. 20]

Die Embedded-Methode wählt die Merkmale während des Trainingsprozesses implizit im Lernalgorithmus [133, S. 1166-1167]. Die Anwendung ist daher abhängig vom benutzten Lernalgorithmus und nicht für alle Verfahren möglich. Lernverfahren, die auf Entscheidungsbäumen basieren, sind indessen geeignet. Die Verbesserungen des Unreinheitsmaßes während der Erzeugung des Entscheidungsbaums geben Aufschluss über den Einfluss einzelner Merkmale (Kap. 5.3.1). Der Rechenaufwand der Embedded-Methode ist damit geringer als bei der Wrapper-Methode, weil der Lernalgorithmus nur einmalig durchlaufen werden muss.

## Diskussion und Anwendung

Die Bestimmung einer Methode zur Merkmalsauswahl läuft für die beiden verwendeten Lernalgorithmen Random Forest und SVM getrennt ab. Während der Random Forest bereits implizit nach der Embedded-Methode eine Merkmalsauswahl durchführt, hat die SVM in der Grundform keine solche Möglichkeit.

Der Entscheidungsbaum besitzt aufgrund der impliziten Merkmalsauswahl ein robustes Verhalten gegenüber unwichtigen Merkmalen. Bei der Weiterentwicklung zum Random Forest wird jedoch im Trainingsprozess an jedem Knoten nur noch eine Teilmenge der Merkmale ausgewertet. Ein hochdimensionaler Merkmalsvektor mit vielen unwichtigen Merkmalen, wie er häufig bei Bildanalysen auftritt, würde hier ein Problem darstellen, weil nur noch unwichtige Merkmale zur Verfügung stehen. Da das im vorliegenden Anwendungsfall nicht zutrifft, kann im folgenden Trainingsprozess trotzdem der gesamte Merkmalsvektor übergeben werden. Die damit für den Random Forest gewählte Embedded-Methode verwendet einerseits im Lernprozess nur die wichtigen Merkmale, andererseits liefert sie auch direkt eine Rangliste zur Bestimmung der Wichtigkeit der Merkmale.

Der Trainingsalgorithmus der SVM kann hingegen die relevanten Merkmale nicht selbst auswählen, weshalb eine zusätzliche Merkmalsauswahl erfolgen muss. Die Filter-Methode besitzt gegenüber der Wrapper-Methode bezüglich der Rechenzeit deutliche Vorteile. Einige Merkmale im verwendeten Datensatz sind jedoch sehr ähnlich. Dadurch ist bei der Filter-Methode zu befürchten, dass aufgrund der Einzelbewertung jedes Merkmals zwar die besten nur für sich bewerteten Merkmale ausgewählt, andere ergänzende, sekundäre Merkmale jedoch zu stark ignoriert werden. Weil damit die bessere Güte des Merkmalauswahlprozesses einer Wrapper-Methode nicht erreicht werden kann, wird für die SVM die Wrapper-Methode mit einer Vorwärtsselektion gewählt [133, S. 1178].

Dazu durchlaufen alle fünf SVM-Modelle (Kap. 5.4.3) aus verschiedenen Zeitfensterenden die Wrapper Vorwärtsselektion bis jeweils die zehn wichtigsten Merkmale bestimmt sind. Durch den statistischen Einfluss der vorgeschalteten Kreuzvalidierung wird dieses Vorgehen zweimal durchgeführt. Die sich ergebenden Merkmale werden zu einer Gruppe vereint, in der jedes Merkmal nur noch einmal auftritt. Es verbleiben somit nach der Merkmalsauswahl der SVM 40 Merkmale für die Geradeausfahrten sowie 45 Merkmale für die Kurvenfahrten (Anhang

A 5.3.4). Damit erhalten alle SVM-Modelle mit derselben Eingangsdatenkombination auch den gleichen Satz an Merkmalen. Es sei darauf hingewiesen, dass der Gewichtungswert  $C$  und der Kernelparameter der SVM für die Merkmalsauswahl nach der Wrapper-Methode konstant gehalten werden.

### 5.3.5 Parametrisierung und Detaillierung der verwendeten Klassifikationsmethoden

Die Parametrisierung befasst sich mit allen Einstellmöglichkeiten der Klassifikatoren vor einer Auswertung. Die zur Argumentation verwendeten Analysen beziehen sich auf feste Zeitfensterbereiche zur Merkmalerzeugung.

#### Random Forest

Der Random Forest besitzt als Parameter nur die Anzahl an Entscheidungsbäumen  $n_{tree}$  (Kap. 5.3.1). Zur Bestimmung von  $n_{tree}$  werden vier Modellen aus dem Folgekapitel 5.4.1 exemplarisch ausgewertet. Für die Datensätze Geradeausfahrt und Kurvenfahrt mit der Zeitfensterlänge 1 s und den beiden Zeitfensterenden 1 s und 5 s wird jeweils das Maß ROC AUC (*engl.* Receiver Operating Characteristic Area Under Curve) für die Klassifikationsgüte über verschiedene  $n_{tree}$  berechnet (Abb. 5.15). Die Bewertungsgröße ROC AUC wird im kommenden Abschnitt 5.3.6 detailliert beschrieben. Unabhängig vom verwendeten Modell ist eine Konvergenz gegen einen oberen Grenzwert erkennbar. Je größer die Anzahl  $n_{tree}$ , desto höher ist die Rechenzeit. Eine Anzahl von 150 Bäumen erscheint nahe genug am Grenzwert, somit wird fortan für alle folgenden Random Forest Modelle  $n_{tree} = 150$  gesetzt.

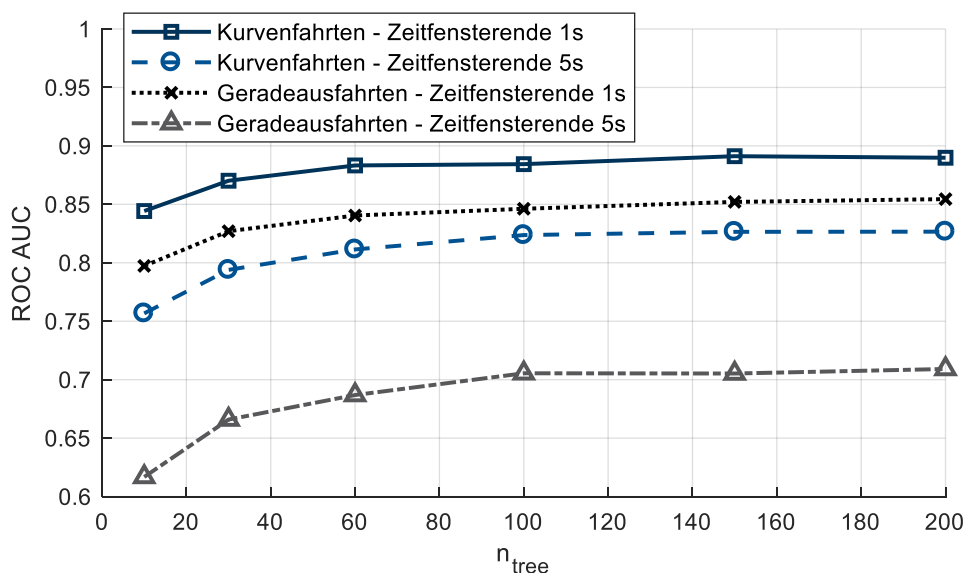


Abb. 5.15 Parameteranalyse für  $n_{tree}$  beim Random Forest nach [113, S. 48]

Der Erstellalgorithmus ist dem Paket fitcensemble von Ensemble Learning Methoden für Klassifikationsaufgaben des Softwarepakets MATLAB R2017a entnommen [136]. Die beispielhafte Rechenzeit für einen Aufruf zur Erstellung und Auswertung von Random Forest Modellen mit 10-facher Kreuzvalidierung eines festgelegten Zeitfensters (Kap. 5.4.1) beträgt gemittelt über drei Durchläufe 312 s. Hierbei werden 16.026 Datensätze von Geradeausfahrten mit jeweils 87 Merkmalen übergeben. Die 10-fache Kreuzvalidierung (Kap. 5.3.2) führt zu insgesamt zehn

Random Forest Modellen. Die Anzahl der Entscheidungsbäume je Random Forest Modell ist  $n_{tree} = 150$ . Als System dient ein Intel® Core™ i5-6300U CPU @ 2.4 GHz mit 8 GB RAM, Windows 7 Enterprise und MATLAB R2017a. Der detaillierte Aufruf findet sich im Anhang A 5.3.5.

## Support Vector Machine

Für die SVM - Modelle stehen der Gewichtungswert  $C$  und der Kernelparameter  $\sigma$  als Einstellmöglichkeiten zur Verfügung (Kap. 5.3.1). Zur Bestimmung sinnvoller Werte erfolgt wiederum eine exemplarische Auswertung der Datensätze Geradeausfahrt und Kurvenfahrt mit der Zeitfensterlänge 1s und dem Zeitfensterende 0,5s. Abb. 5.16 zeigt beispielhaft für die Geradeausfahrt die invertierte Klassifikationsgüte ROC AUC sowohl über den Gewichtungswert  $C$  als auch über den Kernelparameter  $\sigma$ . Mit Hilfe der Stützstellen wurde eine Bayes'sche Optimierung durch Nutzung der Funktion bayesopt des Softwarepakets MATLAB R2017a zur Wahl der optimalen Parameter durchgeführt [137]. Der Gewichtungswert  $C$  hat demzufolge keinen großen Einfluss auf die Klassifikationsgüte und wird fortan auf  $C = 1$  gesetzt. Das gilt ebenso für den Datensatz Kurvenfahrt. Für den Kernelparameter  $\sigma$  liegt das Optimum für den Datensatz Geradeausfahrt bei 2,5 und wird auch im Folgenden für diesen Datensatz weiterverwendet. Für den Datensatz Kurvenfahrt liefert der Wert 20 für den Kernelparameter die besten Ergebnisse und wird ebenso fortan eingesetzt.

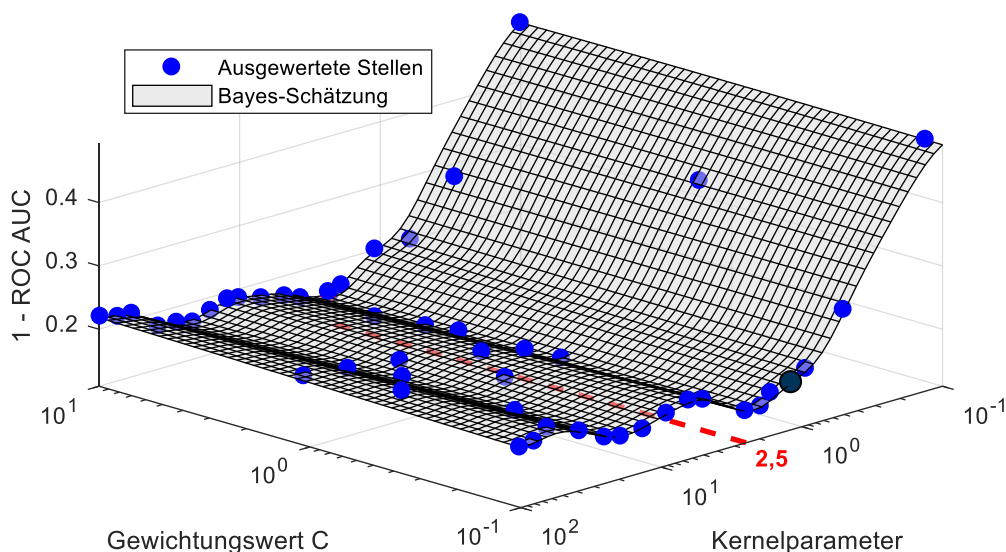


Abb. 5.16 Parameteranalyse für Gewichtungswert  $C$  und Kernelparameter  $\sigma$  bei der SVM für Geradeausfahrt nach [113, S. 49]

Die Erstellung des SVM-Klassifikationsmodells erfolgt mit der Funktion `fitsvm` des Softwarepakets MATLAB R2017a [138]. Die beispielhafte Rechenzeit für einen Aufruf zur Erstellung und Auswertung von SVM Modellen mit 10-facher Kreuzvalidierung eines festgelegten Zeitfensters (Kap. 5.4.3) beträgt gemittelt über drei Durchläufe 31 s. Hierbei werden 14.698 Datensätze von Geradeausfahrten mit jeweils 40 Merkmalen übergeben. Die 10-fache Kreuzvalidierung (Kap. 5.3.2) führt zu insgesamt zehn SVM-Modellen. Der Kernelparameter wird auf  $\sigma = 2,5$  festgelegt. Als System dient ein Intel® Core™ i5-6300U CPU @ 2.4 GHz mit 8 GB RAM, Windows 7 Enterprise und MATLAB R2017a. Der detaillierte Aufruf findet sich im Anhang A 5.3.5.

### 5.3.6 Auswahl der Bewertungsgröße

Gütemaße zur Bewertung einer Klassifikationsmethode sollen eine Aussage über die Richtigkeit einer prädizierten Zielgröße liefern. Aufgrund diskreter Zielgrößen ist die Differenzbildung zwischen wahrer und bestimmter Zielgröße wie bei Regressionsmethoden für die Klassifikation nicht geeignet. Dieser Abschnitt stellt zuerst einige Bewertungsgrößen für eine binäre Klassifikation aus dem Stand der Wissenschaft vor. Anschließend erfolgt ein bewertender Vergleich hinsichtlich des vorliegenden Anwendungsfalls dieser Arbeit.

#### Stand der Wissenschaft: Bewertungsgrößen für Klassifikationsmethoden

Dieses Kapitel stellt zwei Arten von Bewertungsgrößen vor: Die Konfusionsmatrix mit daraus abgeleiteten Größen gibt eine Aussage zur Richtigkeit der diskreten Klassenzuordnung. Die ROC (*engl.* Receiver Operating Characteristic) - Kurve beinhaltet ebenso deren Wahrscheinlichkeit der Klassenzuordnung.

##### Konfusionsmatrix und abgeleitete Größen

Die Konfusionsmatrix zeigt die wahren und geschätzten Klassenzugehörigkeiten in Form einer Matrix [124, S. 254-257]. Im vorliegenden, binären Fall ergibt sich daraus die Dimension 2x2 (Abb. 5.17). Das Attribut „positiv“ steht für die Anwesenheit eines Events (hier: Unfall), „negativ“ entsprechend für dessen Abwesenheit (hier: kein Unfall). Auf der Hauptdiagonalen liegen Felder richtiger Klassenzuordnung. Die Nebendiagonale enthält zum einen Fehler 1. Art (FP: falsch positiv), die Falschalarme darstellen, sowie Fehler 2. Art (FN: falsch negativ), die einen fälschlicherweise ausbleibenden Alarm zeigen. Aus den diskreten Häufigkeiten der vier Felder lassen sich nun direkt Bewertungsgrößen ableiten.

Wahre Klasse	Unfall	<b>RP</b> richtig positiv	<b>FN</b> falsch negativ
	Kein Unfall	<b>FP</b> falsch positiv	<b>RN</b> richtig negativ
		Unfall	Kein Unfall
		<b>Prädizierte Klasse</b>	

Abb. 5.17 Konfusionsmatrix einer binären Klassifikation

Das Verhältnis aus richtig zugeordneten Fällen zu allen Fällen wird als Treffergenauigkeit *GEN* bezeichnet [139, S. 87]:

$$GEN = \frac{RP + RN}{RP + FN + FP + RN} \quad (5.17)$$

Vorteil dieser Methode ist dessen Einfachheit und Interpretierbarkeit. Es wird jedoch nicht zwischen den verschiedenen Fehlerarten unterschieden. Bei ungleich verteilten Datensätzen liefert *GEN* keine hilfreichen Aussagen. Am Beispiel einer 99% zu 1% Verteilung erreicht ein durchwegs auf die Mehrheit prädizierendes Modell eine Treffergenauigkeit von 99%.

Zwei weitere Bewertungsgrößen adressieren genau dieses Problem. Zum einen vergleicht die Sensitivität, auch Richtig-positiv-Rate  $RPR$  genannt, die richtig prädizierten Unfälle mit allen Unfällen [139, S. 87]:

$$RPR = \frac{RP}{RP + FN}. \quad (5.18)$$

Zum anderen errechnet sich die Falsch-positiv-Rate  $FPR$  aus dem Verhältnis der falsch positiven Fälle zu allen Nicht-Unfällen [139, S. 87]:

$$FPR = \frac{FP}{FP + RN}. \quad (5.19)$$

Für weitere denkbare Bewertungsvarianten auf Basis der Konfusionsmatrix sei auf [75, S. 180ff] verwiesen.

### ROC-Kurve und ROC AUC

Das Ergebnis einer Klassifikationsmethode ist häufig eine kontinuierliche Messgröße [75, S. 185][124, S. 247]. Ein Entscheidungsbaum bestimmt ebenso über die relative Häufigkeit an jedem Blatt ein internes Zuordnungsmaß, das von 0 bis 1 läuft (Kap. 5.3.1). Unterhalb des Grenzwertes von 0,5 wird ein Datensatz einer Klasse, darüber der jeweiligen anderen Klasse zugeordnet. Folglich hat dieses Zuordnungsmaß Gemeinsamkeiten mit einer Wahrscheinlichkeit der Klassenzuordnung. Die mathematische Definition einer Wahrscheinlichkeit ist hingegen nicht erfüllt. Trotzdem ermöglicht die kontinuierliche Eigenschaft dieses Maßes die weitere Verwendung als Kritikalität des Fahrzustandes in Kap. 5.4.

Bei der Beurteilung einer Klassifikationsmethode führt ein gewählter Schwellwert auch zu einem zugehörigen Wertepaar aus Richtig-positiv-Rate ( $RPR$ ) und Falsch-positiv-Rate ( $FPR$ ). Wenn man nun für verschiedene Schwellwerte diese Wertepaare in einem Diagramm darstellt, resultiert die Receiver-Operating-Characteristic-Kurve (ROC-Kurve) [75, S. 185ff][124, S. 262ff]. Damit lassen sich verschiedene Modelle hinsichtlich ihrer Klassifikationsgüte vergleichen. Je weiter sich die Kurve der linken oberen Ecke annähert, desto besser ist das Ergebnis. Ein ideales Ergebnis ergäbe eine Sprungfunktion. Die ROC-Kurve eines Modells, das die Klassen nicht trennen kann, liegt auf der Diagonalen des Diagramms. Abb. 5.18 zeigt beispielhaft eine ROC-Kurve und das Wertepaar aus  $RPR$  und  $FPR$  für den Schwellwert 0,5.

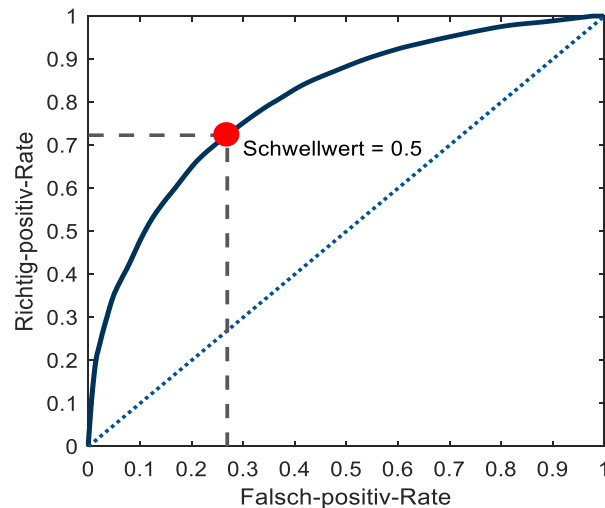


Abb. 5.18 ROC-Kurve mit Schwellwert nach [113, S. 26]

Im Normalfall führt die Kopplung von  $RPR$  und  $FPR$  dazu, dass mit der Wahl eines anderen Schwellwertes zwar einerseits die  $RPR$  erhöht werden kann, andererseits aber auch die  $FPR$  und damit der Fehler steigt. Je nach Anwendungsfall werden durch falsch positive und falsch negative Entscheidungen unterschiedliche Kosten beziehungsweise Risiken verursacht [75, S. 186]. Die optimale Wahl des Schwellwertes muss dem Sorge tragen und strebt hierbei einen Kompromiss an. Letztendlich führt die Wahl eines solchen Arbeitspunktes wieder zu einer Konfusionsmatrix, wie im vorherigen Abschnitt bereits dargestellt wurde.

Die Berechnung der Fläche unter der Kurve ROC AUC (*engl.* area under curve) gibt Auskunft über die generelle Leistungsfähigkeit des Modells. Dieser Kennwert erlaubt eine gute Vergleichbarkeit zwischen mehreren Modellen. Es gehen jedoch Informationen zur Form der Kurve verloren, was insbesondere für Anwendungen in ausgewählten Kurvenbereichen problematisch sein kann. Ein weiterer Nachteil theoretischer Natur der ROC-Kurve ist, dass nur zwei Klassen verglichen werden können, was aber im vorliegenden binären Anwendungsfall kein Problem darstellt [75, S. 264]. Von Vorteil ist hingegen die Unabhängigkeit der beiden Kennwerte  $RPR$  und  $FPR$  und damit der ROC-Kurve von der Verteilung (oder Ungleichverteilung) der Datensätze [124, S. 426].

### Diskussion und Entscheidung für eine Bewertungsgröße

Die Bewertungsgrößen Treffergenauigkeit GEN und ROC AUC werden vergleichend anhand von Random Forest Modellen dargestellt. Die Modelle werden zeitfensterspezifisch für eine Zeitfensterlänge von 1 s sowohl angelernt als auch ausgewertet und stammen aus dem Abschnitt 5.4.1. Die Eingangsdatensätze variieren dabei zwischen „gleichverteilt“, „ungleich verteilt“ sowie „ungleich verteilt und gewichtet“. „Gleichverteilt“ bedeutet, dass gleich viele Unfall- wie Baseline-Datensätze verwendet werden. „Ungleich verteilt“ lässt die Datensatzanteile unverändert, wie sie in SHRP2 auftreten. „Ungleich verteilt und gewichtet“ nutzt einen Ansatz, der alle Unfalldatensätze mit dem Verhältnis von Baseline- zu Unfalldatensätzen gewichtet. Abb. 5.19 zeigt die ROC AUC (links) und die Treffergenauigkeit (rechts).



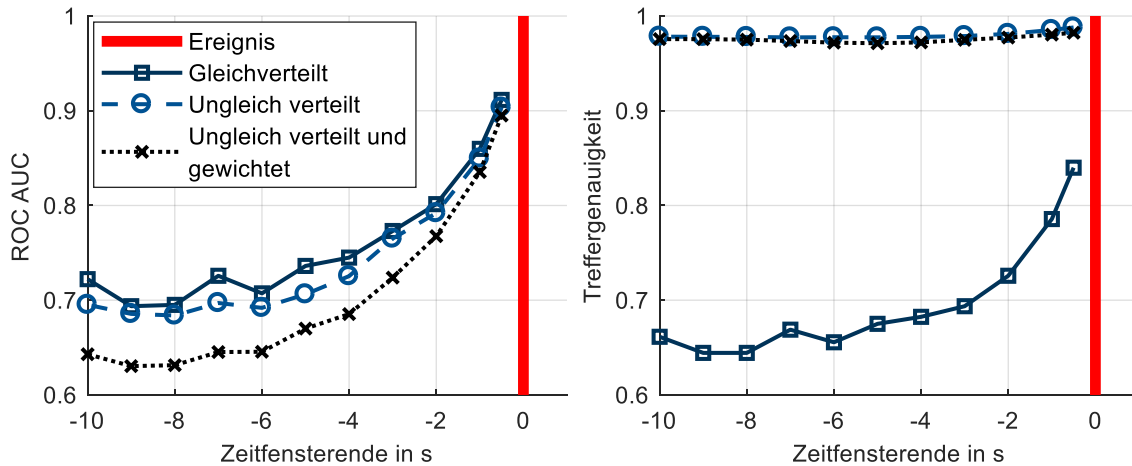


Abb. 5.19 Vergleich der Bewertungsgrößen ROC AUC (links) und Treffergenauigkeit (rechts) nach [113, S. 50]

Der Verlauf beider Bewertungsgrößen für gleichverteilte Datensätze ist ähnlich. Der Anstieg zum Ereigniszeitpunkt hin ist aus Gründen der Logik sinnvoll. Je weniger weit prädiziert werden muss, desto besser wird die Klassifikationsgüte. Für ungleichverteilte Datensätze ist jedoch ein Problem der Treffergenauigkeit sichtbar. Die Unterscheidbarkeit für die einzelnen Modelle ist nicht mehr gegeben. Insbesondere die hier wichtige Tatsache der Ungleichverteilung der Datensätze lässt die Treffergenauigkeit durchgehend hohe, ähnliche Werte annehmen. Eine differenzierte Beurteilung der Klassifikationsgüte mit der Treffergenauigkeit ist damit nicht möglich.

Am obigen Fallbeispiel wurde nachgewiesen, dass die Treffergenauigkeit als Bewertungsgröße nur bei gleichverteilten Datensätzen sinnvoll ist. Die Auswertung mit ausschließlich gleichverteilten Datensätzen kann bei den vorliegenden Daten jedoch den Großteil der Baseline-Fälle nicht berücksichtigen. Die darin enthaltenen Informationen würden damit nicht in die Modellerzeugung einfließen und folglich zu schlechteren Modellen führen. Aus diesem Grund wird im weiteren Verlauf trotz der geringeren Interpretierbarkeit die ROC AUC zur weiteren Beurteilung der Klassifikationsgüte verwendet.

### 5.3.7 Auswertung

Die Auswertung orientiert sich an drei Möglichkeiten der Variation: Zeitfensterbereich zur Merkmalerzeugung, Methode und Merkmalsmix. Ziele jeder Auswertung sind Aussagen zur Klassifikationsgüte, Wichtigkeit der verwendeten Merkmale und Kritikalität des Fahrzustandes. Tabelle 5.9 zeigt die Zuordnung der Auswertungsvariationen und -ziele auf die Unterkapitel in 5.4.

Tabelle 5.9 Vorgehen der Auswertung

		Kapitel			
		5.4.1	5.4.2	5.4.3	
Auswertungsvariationen	Variation Zeitfensterbereich	<b>Variation von Zeitfensterlänge und Zeitfensterende</b> Erzeugung mehrerer Modelle (je Zeitfenster wird ein Modell erzeugt und ausgewertet)	•		•
		<b>Kontinuierliche Zeitreihenklassifikation</b> Erzeugung und Auswertung eines Modells für mehrere Zeitfenster		•	
	Variation Methode	<b>Random Forest</b>	•	•	
		<b>Support Vector Machine</b>			•
	Variation Merkmalsmix	<b>Einbeziehen aller voraussagbaren, langsam veränderlichen Einflussfaktoren</b>	•	•	•
<b>Einbeziehen des Fahrerzustandes</b>			•		
Ziele	<b>Klassifikationsgüte</b>	•	•	•	•
	<b>Wichtigkeit der Merkmale</b>		•	•	•
	<b>Kritikalität des Fahrzustandes</b>		•	•	

Die erste Dimension der Variation betrifft den Bezugszeitraum des Modells. Einerseits können mehrere, spezialisierte Modelle für zugehörige Zeitfensterbereiche angelernt und wieder ausgewertet werden. Andererseits besteht die Möglichkeit, ein einzelnes Modell für mehrere Zeitfensterbereiche anzulernen und auszuwerten. Dieser Anwendungsfall wäre bei einer kontinuierlichen Zeitreihenklassifikation nötig.

Die Variation der Methode umfasst die maschinellen Lernmethoden Random Forest und Support Vector Machine. Die Funktionsweise der Methoden wurde bereits in Kap. 5.3.1 detailliert vorgestellt. Je nach verwendetem Modell werden unterschiedliche Arten zur Bestimmung der Wichtigkeit der Merkmale verwendet (Kap. 5.3.4).

Als drittes wird der verwendete Merkmalsmix variiert. Es werden immer alle im Fahrzeug vorliegenden beziehungsweise voraussagbaren, langsam veränderlichen Einflussfaktoren mitverwendet. Optional kommt der zeitlich schnell veränderliche Fahrerzustand, bestehend aus Nebenaufgaben, Fahrerbeeinträchtigung und Hände am Lenkrad, hinzu. Eine robuste Prädiktion dieser Fahrervariablen über mehrere Sekunden ist nicht möglich und deshalb nur eingeschränkt als Merkmal nutzbar.

Die Variation der betrachteten Manöver Geradeausfahrt und Kurvenfahrt wird durchgehend für alle Auswertungen umgesetzt und ist darum nicht gesondert in Tabelle 5.9 aufgeführt.

In Abschnitt 5.4.1 werden auf festgelegten Zeitfenstern vor einem Ereignis jeweils zugehörige Random Forest Modelle angelernt und getestet. Dabei sind Aussagen bezüglich der erreichbaren Güte für verschiedene Zeitfenster zu erwarten. Ebenso werden die wichtigsten Merkmale für verschiedene Zeitfensterenden dargestellt. Eine zusätzliche Variation unter Einbeziehen des vollständigen Fahrerzustandes verschafft eine Vorstellung, wie viel ein korrekt prädizierter Fahrerzustand zur Kritikalitätsschätzung beitragen kann. Außerdem wird gezeigt,

wie sich ein mögliches Kritikalitätsmaß, das sich aus den Random Forest Modellen erzeugen lässt, vor einem potentiellen Unfall verhält.

Abschnitt 5.4.2 basiert auf einem einzelnen Random Forest Modell, das mit Merkmalen aus verschiedenen Zeitfenstern gelernt und getestet wird. Damit eignet es sich für eine kontinuierliche Zeitreihenklassifikation. Es werden die Klassifikationsgüte des Modells, die wichtigsten Merkmale sowie die Kritikalitätsbewertung des Fahrzustandes untersucht.

Abschließend führt Abschnitt 5.4.3 die Untersuchungen zur Klassifikationsgüte und Wichtigkeit der Merkmale von Modellen für festgelegte Zeitfenster aus Kap. 5.4.1 zum Vergleich noch einmal mit einem SVM-Modell aus.

## 5.4 Ergebnisse und Diskussion

Dieser Abschnitt präsentiert die Ergebnisse in den Kategorien Klassifikationsgüte, Wichtigkeit der Merkmale sowie Kritikalität des Fahrzustandes. Die umgesetzten Auswertungsvariationen des Merkmalsmix, der Methoden und des Zeitfensterbereichs sind in Kap. 5.3.7 dargestellt. Außerdem erfolgen eine Interpretation der Ergebnisse und eine Diskussion bezüglich potentieller Anwendungsfälle. Die Auswertungen dieses Kapitels basieren auf der zu diesem Thema vom Autor konzipierten und betreuten Studienarbeit von YE [113].

### 5.4.1 Random Forest Modelle für festgelegte Zeitfenster vor einem Ereignis

Die Random Forest Modelle dieses Abschnitts werden auf festgelegten Zeitfenstern vor einem Ereignis angelernet und getestet. Jedes Modell ist damit an ein zugehöriges Zeitfenster gekoppelt. Es wird nur aus Merkmalen des festgelegten Zeitfensters erzeugt und liefert auch nur dafür Aussagen. Jedes Zeitfenster ist definiert durch die Zeitfensterlänge und das Zeitfensterende vor einem Ereignis (Kap. 5.3.3).

Von den Merkmalen aus langsam veränderlichen Kritikalitätsmaßen (Kap. 5.3.3) werden nur OR\_Sicht, OR\_quasistatisch und OR\_prädizierbar weiterverwendet. Das Merkmal OR\_Fahrerzustand ist im Voraus nicht verlässlich für den Ereigniszeitpunkt prädizierbar und wird demzufolge in diesem Abschnitt vorerst nicht in den Schätzprozess miteinbezogen. Eine Ausnahme bildet die dritte Auswertung, die den Einfluss des Fahrerzustandes auf die Klassifikationsgenauigkeit untersucht.

### Einfluss des Zeitbereichs auf die Klassifikationsgüte

Die Wahl des Zeitbereichs hat großen Einfluss auf die Merkmalerzeugung und die Klassifikationsaufgabe. Für eine kontinuierliche Klassifikation während einer Fahrt legt sie darüber hinaus den Zeithorizont fest, mit dem ein Modell die Unfallgefahr im Voraus bestimmen kann. Beispielsweise erlaubt ein Modell, das mit Merkmalen aus dem Zeitbereich -5 s bis -3 s vor einem möglichen Ereignis erzeugt wird, nur Aussagen für die Situation in 3 s.

In Abb. 5.20 ist die Klassifikationsgüte ROC AUC in Abhängigkeit des Zeitbereichs für Geradeaus- und Kurvenfahrten dargestellt. Als Parameter variieren jeweils die Zeitfensterlänge und

das Zeitfensterende vor einem potentiellen Ereignis. Aus jeder Kombination von Zeitfensterlänge und Zeitfensterende wird ein Satz von Merkmalen generiert. Daraus wird jeweils ein eigenes Modell erzeugt und ausgewertet. Die Manöver Geradeaus- und Kurvenfahrt haben ebenso eigene Modelle. Der Vorgang für Modellerzeugung und -auswertung wurde für jedes Modell fünfmal durchgeführt und die gemittelte Klassifikationsgüte ROC AUC angegeben.




Abb. 5.20 Einfluss des Zeitbereichs auf die Klassifikationsgüte ROC AUC für Geradeausfahrten (oben) und Kurvenfahrten (unten) nach [113, S. 53]

Der Erwartung entsprechend steigt die Klassifikationsgüte für beide Manövertypen mit einem später liegenden Zeitfensterende an. Je näher die Merkmale an einem möglichen Ereignis erzeugt worden sind, desto größer ist die Chance, dass sich in den Merkmalen bereits Hinweise für das Ereignis befinden.

Die Klassifikationsgüte bei den Geradeausfahrten stellt sich als weitestgehend unabhängig von der Zeitfensterlänge heraus und ist vor allem durch die Wahl des Zeitfensterendes getrieben. Der Verlauf gestaltet sich insgesamt als relativ gleichmäßig. Lediglich die Kombination der Zeitfensterlänge 10 s mit dem Zeitfensterende -10 s stellt einen Ausreißer dar. Dieser lässt sich dadurch erklären, dass die beiden Klassen zufällig aufgrund der Werte eines Merkmals gut trennbar sind. Es handelt sich dabei um das Merkmal  $\text{fft}(a_z)$  der diskreten Fouriertransformation von 3 Hz bis 5 Hz, das eigentlich nur eine geringe physikalische Aussagekraft besitzt und keine direkte kausale Verbindung zu einem möglichen Unfall darstellt.

Die Übergänge zwischen ähnlichen Zeitbereichen bei den Kurvenfahrten sind im Vergleich zu den Geradeausfahrten größeren Schwankungen unterworfen. Ein Grund dafür ist die geringere Anzahl von Datensätzen mit Unfällen, wodurch die Merkmale einzelner Zeitbereiche von einigen speziellen Unfällen stärker hervortreten. Insgesamt weisen die Kurvenfahrten eine allgemein höhere Klassifikationsgüte auf. Eine mögliche Ursache könnte die manuelle Aussortierung von Fällen sein (Kap. 5.3.2). Es wurden dabei Fälle mit offensichtlichen Sensorfehlern sowie unkritische Fälle mit leichten Bordsteinremplern ausgeschlossen.

Da die Klassifikationsgüte kaum von der Zeitfensterlänge, sondern vielmehr vom Zeitfensterende abhängt, wird die Zeitfensterlänge in den folgenden Abschnitten auf 1 s festgelegt. Durch diese Wahl sind ausreichend fein aufgelöste Analysen bezüglich der Wichtigkeit von Merkmalen für einzelne Zeitbereiche zu erwarten. Die Modelle mit der Zeitfensterlänge von 1 s entsprechen jeweils den ersten Spalten in Abb. 5.20.

### **Einfluss des Zeitfensterendes auf die Wichtigkeit der Merkmale**

Jedes Modell mit festgelegtem Zeitfenster bewertet die Wichtigkeit der Merkmale im Schätzprozess unterschiedlich. In diesem Abschnitt werden die wichtigsten Merkmale mit einer Zeitfensterlänge von 1 s und variablem Zeitfensterende dargestellt. Die untersuchten Zeitfensterenden erstrecken sich von -10 s bis -1 s im 1 s-Takt. Um den Zeitraum vor einem potentiellen Ereignis noch feiner aufzulösen, ist zusätzlich der Wert 0,5 s hinzugefügt.

Die Ranglisten für die Merkmale sind aus den relativen Wichtigkeiten während des Random Forest Trainingsprozesses erstellt. Dafür wurde der Vorgang für Modellerzeugung und -auswertung pro Zeitfensterende elfmal durchgeführt und daraus der Mittelwert gebildet. Damit kann für jedes Modell respektive Zeitfensterende die Rangfolge der wichtigsten Merkmale erstellt werden. Abb. 5.21 zeigt die Wichtigkeit der 14 bedeutendsten Merkmale für die Geradeaus- und Kurvenfahrt. Die enthaltenen Merkmale gehören in mindestens einem der Modelle zu den sechs wichtigsten. Merkmale aus ähnlichen Signalen beziehungsweise Erzeugungsmethoden sind zur Veranschaulichung möglichst zusammen aufgeführt.

Für die Geradeausfahrt sind für die Zeitbereiche kurz vor dem Ereignis vor allem Merkmale aus der Längsbeschleunigung relevant. Das Ergebnis kann mit der Bremsreaktion des Fahrers auf eine nahende Gefahrensituation erklärt werden. Bei Kurvenfahrten ist die Längsbeschleunigung in diesem Zeitbereich im kombinierten Merkmal mit dem reibwertbasierten  $\text{OR}_{my}$  zu finden. Zusätzlich treten besonders die kombinierten Merkmale aus Querschleunigung und Reibwertinformation auf. Der Hauptindikator für einen Unfall in einer Kurve ist demnach eine für die gegebenen Straßenverhältnisse zu hohe Querschleunigung.

Modelle mit einem Zeitfensterende von -3s oder früher sind dagegen stärker von Merkmalen aus der Geschwindigkeit beeinflusst. Dieser Zusammenhang gilt sowohl für Geradeaus- als

## 5 Prädiktive Kritikalitätsschätzung von Unfallsequenzen mit maschinellem Lernen

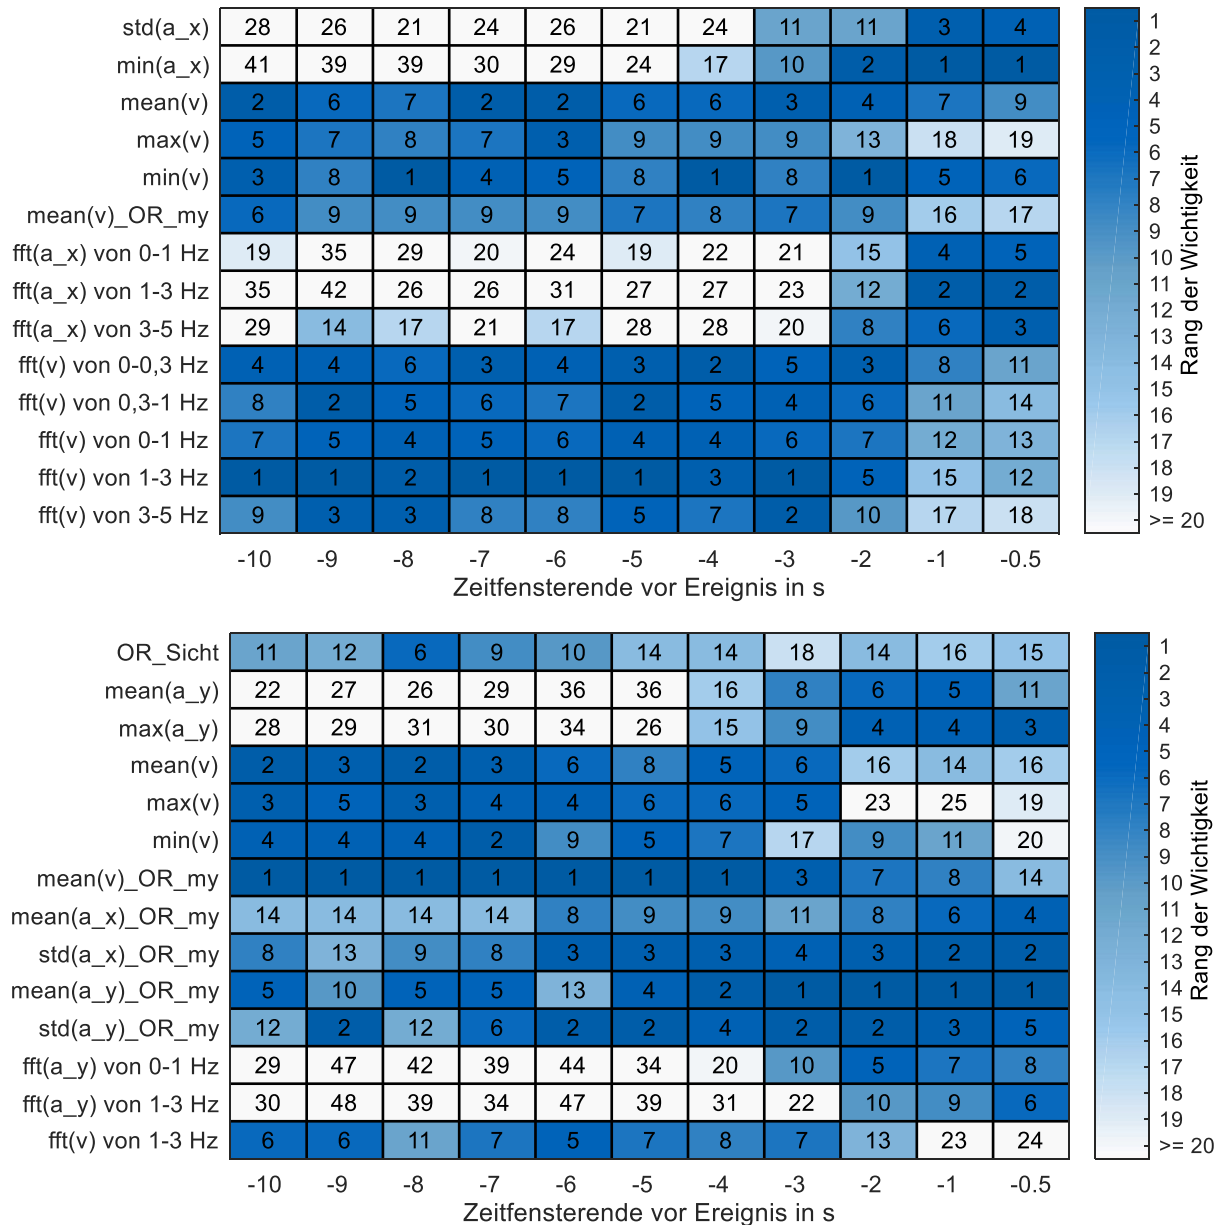


Abb. 5.21 Einfluss des Zeitfensterendes auf die Wichtigkeit der Merkmale bei Geradausfahrt (oben) und Kurvenfahrt (unten) nach [113, S. 54-55]

auch für Kurvenfahrten. Das liegt möglicherweise einerseits an der Gefahr von zu hohen Geschwindigkeiten, andererseits lässt langsamer, innerstädtischer Verkehr auch die Wahrscheinlichkeit eines Auffahrunfalls steigen.

Es ist ebenso ersichtlich, dass alle Merkmale aus langsam veränderlichen Kritikalitätsmaßen wichtiger werden, je früher sich das Zeitfensterende befindet. Der sich daraus ergebende Merkmalswert ist für alle Zeitbereiche gleich und kann damit mehr zur Klassifikation beitragen, als es Zeitreihenmerkmale für frühe Zeitfensterenden könnten. Durch die Kombination von Reibwertinformation und einem fahrzeugkinematischen Signal erhöht sich dessen Bedeutung. Besonders bei den Kurvenfahrten ist das an der Geschwindigkeit und der Längs- sowie Querschleunigung sichtbar. Zusätzlich haben in den Kurvenfahrten viele Unfälle bei Schnee und Regen stattgefunden. Folglich besitzen die Reibwertinformationen, die aus den Variablen Wetter und Straßenoberflächenzustand gebildet wurden, eine hohe Aussagekraft.

Darüber hinaus ist das Fehlen der wissensbasierten Merkmale aus den Radarsensordaten auffällig. Das lässt sich zum einen auf die schlechte Datenqualität des Radarsensors zurückführen. So fehlten in einigen frontalen Auffahrunfällen die Radardaten vollständig oder erkannten das Kollisionsfahrzeug nicht. Andererseits kann die Ursache auch aus der Berechnung der relativen Wichtigkeiten beim Random Forest resultieren. Es werden dabei ähnliche Merkmale als gleichermaßen wichtig eingestuft. Sekundäre Merkmale, die nur bei einem kleinen Anteil an Unfällen eine Aussagekraft besitzen, besitzen hierdurch nur eine geringe Wichtigkeit. Sie werden somit durch die Vielzahl der immer vorhandenen Zeitreihenmerkmale verdrängt.

### **Einfluss des Fahrerzustandes auf die Klassifikationsgüte**

Da der Fahrerzustand nicht verlässlich über mehrere Sekunden für den Ereigniszeitpunkt präzifizierbar ist, wird er grundsätzlich bei den Auswertungen von Modellen für festgelegte Zeitfenster nicht berücksichtigt. Dennoch soll hier dessen Einfluss auf die Klassifikationsgüte dargestellt werden. Dazu werden alle Merkmale miteinbezogen, die Informationen zum Fahrerzustand beinhalten (Kap. 5.3.3). Dazu gehören zum einen die aus langsam veränderlichen Kritikalitätsmaßen generierten Merkmale der Variablen Nebentätigkeiten, Hände am Lenkrad sowie Fahrerbeeinträchtigungen. Zum anderen kommen kombinierte Merkmale hinzu, die den Fahrerzustand mit Umgebungsinformationen verknüpfen.

Die Klassifikationsgüte liegt bei zusätzlicher Verwendung der Informationen zum Fahrerzustand sowohl bei Geradeaus- als auch Kurvenfahrt höher (Abb. 5.22). Folglich stellen beim Random Forest die oben genannten Variablen zum Fahrerzustand gute Indikatoren zur Unterscheidung von Unfällen und Baseline-Fällen dar. Da sie im verwendeten Datensatz immer auf den Ereigniszeitpunkt bezogen sind, ist es im Zeitbereich kurz vor dem Ereignis berechtigt anzunehmen, dass sich deren Zustand nicht mehr verändert. Deshalb können die Modelle ab einem Zeitfensterende von etwa -2s als zulässig betrachtet werden. Für die verwendeten Daten ist somit das Einbeziehen der statischen Fahrerzustandsinformation für prädiktive Kritikalitätsaussagen nur auf ein kurzes Zeitfenster beschränkt. Ungeachtet davon wurde bereits in Abschnitt 4.4.2 dessen großer Einfluss auf die Unfallwahrscheinlichkeit in Form von langsam veränderlichen Kritikalitätsmaßen dokumentiert. Deshalb ist das Einbeziehen eines dynamischen Fahrerzustands in die prädiktive Kritikalitätsschätzung grundsätzlich empfehlenswert.

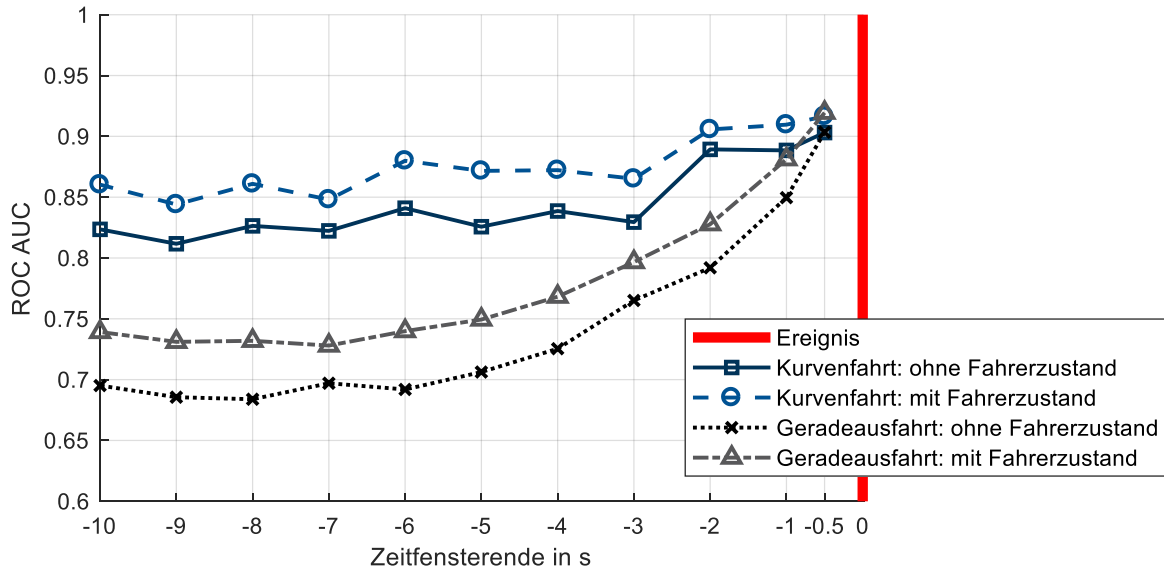


Abb. 5.22 Einfluss des Fahrerzustands auf die Klassifikationsgüte nach [113, S. 56]

## Kritikalitätsschätzung des Fahrzustandes

Bisher wurde nur die Klassifikation von Sequenzen in die beiden diskreten Klassen Unfall und Baseline betrachtet. Für die kontinuierliche, prädiktive Bewertung des Fahrzustandes im Fahrzeug ist aber ein kontinuierliches Maß für die Kritikalität notwendig. Eine Möglichkeit, ein derartiges Maß zu definieren, besteht in der Verwendung der Zwischengröße des Klassifikators während der Auswertung. Jeder Entscheidungsbaum im Random Forest wird bis zur maximalen Größe erzeugt und liefert deshalb als Ergebnis den Wert 0 oder 1. Der Wert 0 korreliert mit Baseline-Fällen, der Wert 1 mit Unfällen. Das Bilden des Medians über alle Bäume liefert für jede Auswertung ein quasikontinuierliches Maß für die Zuordnung des Datensatzes zur Gruppe Unfall beziehungsweise Baseline. Die Anzahl der verwendeten Bäume ( $n_{tree} = 150$ , Kap. 5.3.5) legt die Diskretisierung dieses Kritikalitätsmaßes fest.

In den vorherigen Abschnitten erfolgte die Auswertung der Modelle mit den Testdatensätzen im selben Zeitfenster, aus dem auch die Trainingsdatensätze stammen. Für eine kontinuierliche Kritikalitätsschätzung müsste man, abhängig von der Restzeit bis zum Ereignis, das jeweilige Modell des vorliegenden Zeitfensters auswerten. Allerdings ist der Zeitpunkt eines bevorstehenden Unfalls nicht im Voraus bekannt, was dieses Vorgehen obsolet macht. Die kontinuierliche Kritikalitätsschätzung muss daher durch ein einzelnes Modell erfolgen. Aus diesem Grund wird im Folgenden ein Modell für ein festgelegtes Trainingszeitfenster erzeugt und anschließend mit Daten unterschiedlicher Testzeitfenster ausgewertet. Die Zeitfensterlänge bleibt auch hier konstant bei 1 s, die Zeitfensterenden für Training und Test werden variiert.

Die Auswertung von Unfalldatensätzen von sowohl Geradeaus- als auch Kurvenfahrten für verschiedene Trainings- und Testzeitfensterenden zeigt Abb. 5.23. Die dargestellte Kritikalität entspricht dem Median aller Zwischengrößen für einen ausgewerteten Unfalldatensatz. Der Einfluss des Testzeitfensterendes auf die Kritikalität ist für beide Manövertypen größer als der des Trainingszeitfensterendes. Außerdem steigt die Kritikalität bei jedem Modell mit Annäherung des Testzeitfensters an den Ereignispunkt an, unabhängig des zur Modellerzeugung verwendeten Trainingszeitfensters. Damit könnte jedes der dargestellten Modelle potenziell zur kontinuierlichen Kritikalitätsschätzung verwendet werden. Darüber nimmt die Zwischengröße beim Random Forest für ungleich verteilte Datensätze kleine Werte an. Dies führt selbst



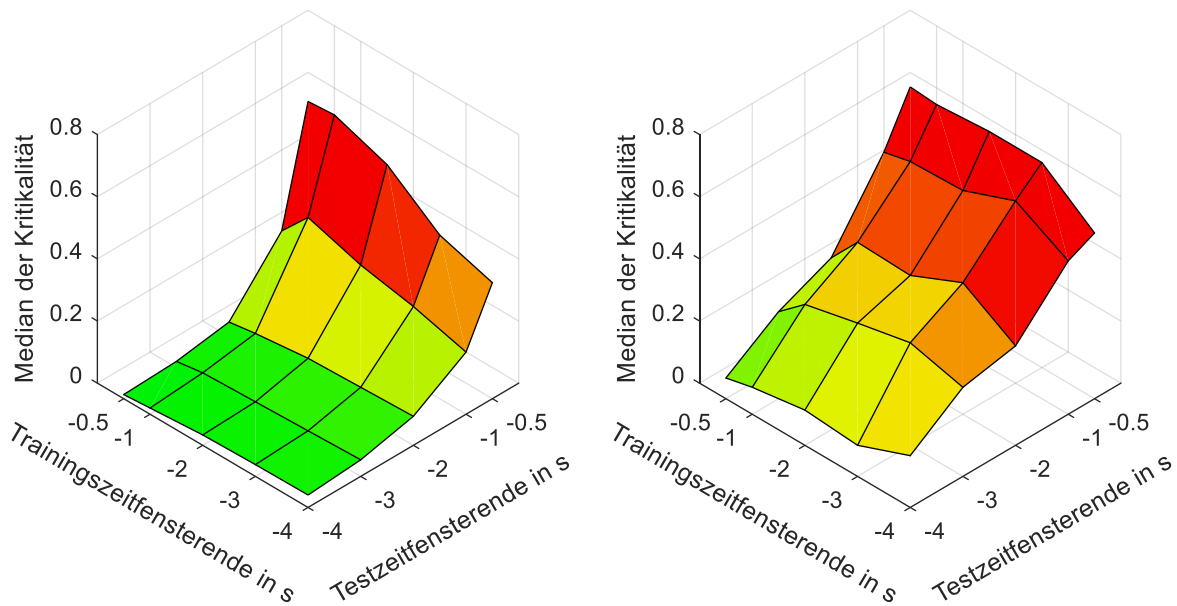


Abb. 5.23 Kritikalitätsschätzung des Fahrzustandes für Geradeausfahrt (links) und Kurvenfahrt (rechts) von Unfalldatensätzen nach [113, S. 58]

in der Auswertung von Unfalldaten, wie es hier der Fall ist, zu Werten unterhalb von 0,1. Zur Beurteilung einer Fahrsituation müsste hier ein Schwellwert definiert werden, der, abhängig vom betrachteten Zeitfenster, den Grenzwert zwischen unkritischen und kritischen Situationen festlegt.

Die Kritikalität von Unfällen in Kurvenfahrten nimmt allgemein höhere Werte als die von Geradeausfahrten an. Besonders für frühere Zeitfensterenden liegt das Niveau deutlich höher. Für die Zeitbereiche kurz vor dem Unfall liegen die Kritikalitätswerte in beiden Abbildungen trotz der starken Ungleichverteilung der Datensätze über 0,5. Damit bestätigt sich das Potenzial der Modelle zur Kritikalitätsschätzung. Es sei angemerkt, dass die Werte im Diagramm stets den Median der Schätzungen darstellen. Nichtsdestotrotz führen einige Unfalldatensätze trotz Annäherung an den Unfallzeitpunkt zu keinem relevanten Anstieg der Kritikalität.

## 5.4.2 Kontinuierliche Zeitreihenklassifikation mit einem Random Forest Modell

Jedes Modell der kontinuierlichen Zeitreihenklassifikation lernt mit Daten verschiedener Zeitfensterbereiche und wird ebenso auch in verschiedenen Zeitfensterbereichen ausgewertet. Das verwendete Vorgehen ist dem „Scenario-Based Random Forest for On-Line Time Series Classification“ Algorithmus von BOTSCH [131, S. 113-122] zur Schätzung diskreter Unfallschwerestufen von standardisierten Unfalltestfällen nachempfunden. Die Bezeichnung „Datensatz“ bleibt in diesem Abschnitt weiterhin ein Ereignis der SHRP2 Daten. Zusätzlich wird der Begriff „Inputpaar“ eingeführt, der eine Kombination eines Vektors mit Merkmalen mit der zugehörigen Zielklasse (Crash und Baseline) bezeichnet. Aus einem Datensatz können durch Variation des Zeitfensters in gewisser Weise beliebig viele Inputpaare erzeugt werden. Die verwendeten Zeitfensterbereiche zur Generierung von Inputpaaren in diesem Abschnitt zeigt Abb. 5.24.

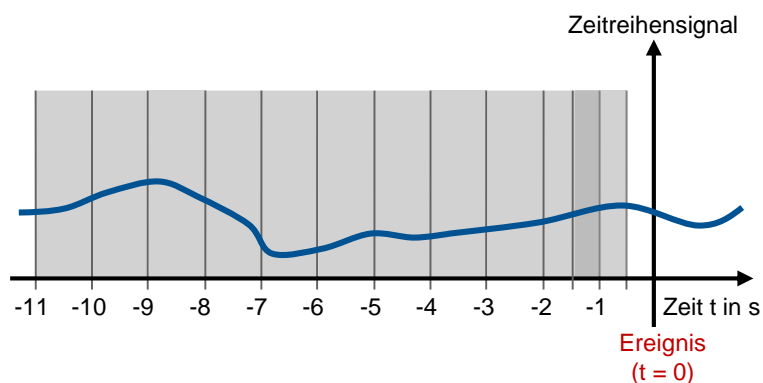


Abb. 5.24 Verwendete Zeitfensterbereiche zur Erzeugung von Inputpaaren für die kontinuierliche Zeitreihenklassifikation nach [113, S. 59]

Die kontinuierliche Klassifikation ist genau genommen eine diskrete Auswertung der Frequenz 1 Hz. Jedes Zeitfenster besitzt weiterhin die Länge 1 s. Die Erzeugung beginnt 11 s vor einem möglichen Ereignis. Um den Zeitbereich kurz vor dem Unfall feiner aufzulösen, ist zusätzlich das Zeitintervall  $[-1,5\text{ s}; -0,5\text{ s}]$  enthalten. Mit diesem Vorgehen wird der gesamte Zeitreihenverlauf vor dem Ereignis verwendet und zugleich eine Überlappung der Zeitfenster nahezu vermieden. Im folgenden Trainingsprozess werden die erstellten Inputpaare unabhängig ihres Zeitbereichs gleichwertig behandelt.

Zwangsläufig geht dieser Ansatz mit einer großen Ähnlichkeit von Inputpaaren eines Datensatzes einher. Es gilt deshalb zu verhindern, dass Trainings- und Auswertungsinpaaire vom selben Datensatz stammen. Dadurch würde die Klassifikationsgüte auf unzulässige Art und Weise positiv beeinflusst. Aus diesem Grund erfolgt die Kreuzvalidierung (Kap. 5.3.2) stets so, dass die Inputpaare eines Datensatzes immer zusammenbleiben.

Die aus den langsam veränderlichen Kritikalitätsmaßen berechneten Merkmale beziehen sich immer auf den Eventzeitpunkt und variieren unterschiedlich stark über die Zeit. Eine zeitkontinuierliche Klassifikation erfolgt hingegen mit Inputpaaren aus verschiedenen Zeitbereichen. Dementsprechend finden nur quasistatische Eventvariablen zur Merkmalerzeugung Verwendung, die sich innerhalb des untersuchten Zeitfensters  $[-11\text{ s}; -0,5\text{ s}]$  nicht verändern. Die Informationen zum Fahrzustand und der Verkehrskomplexität werden deshalb für die folgende Analyse ausgeschlossen. Von den Merkmalsgruppen aus langsam veränderlichen Kritikalitätsmaßen (Kap. 5.3.3) findet somit nur die quasistatische Gruppe OR\_quasistatisch Anwendung.

Die Ergebnisse der folgenden Abschnitte basieren auf zwei Random Forest Klassifikationsmodellen. Diese wurden einmal für Geradeaus- sowie für Kurvenfahrten erzeugt und zeitkontinuierlich ausgewertet. Zunächst erfolgt die Betrachtung der Klassifikationsgüte beider Modelle. Dazu werden die Modelle mit Inputpaaren aus verschiedenen Zeitfenstern erzeugt (Abb. 5.24) und für die zu untersuchenden Zeitfenster ausgewertet. Anschließend wird die Wichtigkeit der Merkmale beider Modelle ermittelt und in Rangtabellen dargestellt. Der letzte Abschnitt stellt die Ergebnisse bei Umsetzung einer kontinuierlichen Fahrzustandsschätzung mithilfe der beiden zeitfensterübergreifenden Modelle vor. Die hieraus resultierende Kritikalitätsbewertung repräsentiert zu jedem Zeitpunkt ein kontinuierliches Kritikalitätsmaß, das so für aktive Sicherheitssysteme Anwendung finden könnte.

## Klassifikationsgüte

Die Klassifikationsgüte legt fest, wie gut ein kontinuierlich schätzendes Modell zwischen Baseline- und Unfallsequenzen unterscheiden kann. Es sei erneut darauf hingewiesen, dass hier, im Vergleich zum vorherigen Abschnitt, nur ein Modell zur Auswertung in verschiedenen Zeitfenstern verwendet wird. Die Ergebnisse der beiden Modelle für Geradeaus- und Kurvenfahrten für die Zeitfensterenden -10 s bis -0,5 s vor dem Ereignis zeigt Abb. 5.25.

Wie bereits bei den Modellen für festgelegte Zeitfenster steigt die Klassifikationsgüte mit Annäherung an den Ereigniszeitpunkt. Demnach kann das Modell aus den Merkmalen mit Nähe zum Ereignis bessere Hinweise für eine korrekte Schätzung ziehen. Als weitere Gemeinsamkeit zur vorherigen Untersuchung ist auch hier eine allgemein bessere Klassifikationsgüte der Kurvenfahrten zu beobachten. Obwohl sich die Güten kurz vor dem Ereignis annähern, liegt das Modell für die Kurvenfahrten zu früheren Zeitfenstern deutlich höher. Neben den Gründen, die bereits in Abschnitt 5.4.1 angeführt wurden, lässt sich dieses Verhalten durch Betrachtung der Wichtigkeit der Merkmale im nächsten Abschnitt erklären.

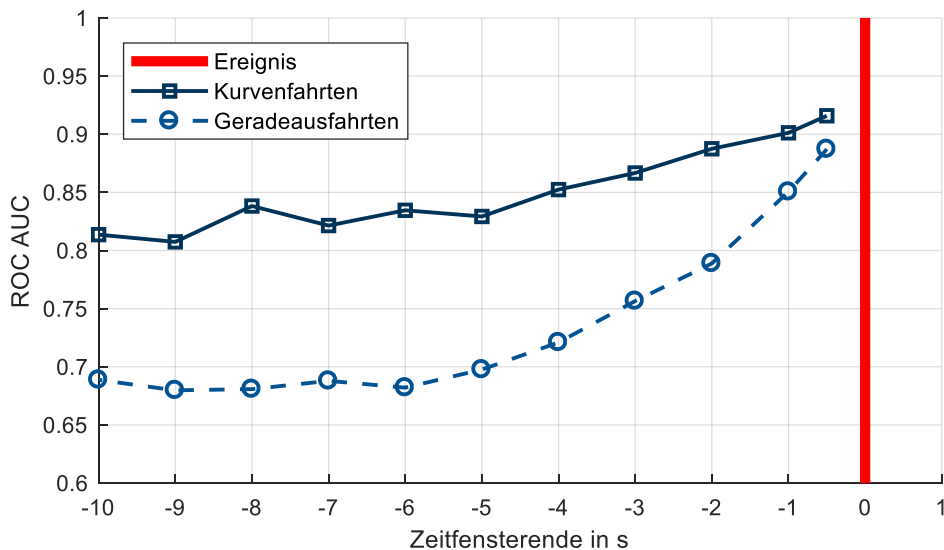


Abb. 5.25 Klassifikationsgüte von Geradeaus- und Kurvenfahrten bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 60]

## Wichtigkeit der Merkmale

Die Berechnung der Wichtigkeit der Merkmale für die beiden Random Forest Modelle für Geradeaus- und Kurvenfahrten erfolgt nach der gleichen Vorgehensweise wie in Abschnitt 5.4.1 durch mehrmalige Auswertung und Mittelwertbildung der relativen Wichtigkeit. Abb. 5.26 zeigt alle Merkmale, die sich bei mindestens einem der beiden Modelle unter den 12 wichtigsten befinden. Merkmale aus ähnlichen Signalen beziehungsweise Erzeugungsmethoden sind zur Veranschaulichung wiederum möglichst zusammen aufgeführt.




Abb. 5.26 Wichtigkeit der Merkmale von Geradeaus- und Kurvenfahrten bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 61]

Beim Vergleich mit dem Ergebnis der festgelegten Zeitbereiche treten hier vor allem jene Merkmale auf, die vorher in mehreren Zeitfenstern von hoher Bedeutung waren. Das resultiert aus der Notwendigkeit, dass bei der zeitkontinuierlichen Schätzung die wichtigsten Merkmale Inputpaare aus unterschiedlichen Zeitfenstern unterscheidbar machen müssen. Falls ein Merkmal nur in wenigen Zeitbereichen zur Klassifikation hilfreich war, verliert es an Bedeutung. Besonders am Beispiel der aus der Längs- und Querbewegung erzeugten Merkmale lässt sich das beobachten. Während diese im vorherigen Abschnitt besonders in wenigen Zeitfenstern kurz vor dem Ereignis eine hohe Wichtigkeit besaßen, tauchen sie bei der zeitkontinuierlichen Schätzung deutlich weniger häufig auf.

Die Fahrzeuggeschwindigkeit nimmt unter diesen Umständen eine bedeutendere Rolle ein. Sie ist in den über standardisierte, statistische Methoden erzeugten Merkmalen auf beiden Seiten häufig zu finden. Im Fall der Geradeausfahrten beinhalten sogar neun der zehn bestplatzierten Merkmale Informationen zur Fahrzeuggeschwindigkeit. Zudem kommen fünf der zehn bestplatzierten Merkmale aus der diskreten Fouriertransformation des Geschwindigkeitssignals. Die Ergebnisse erwecken den Anschein, dass eine längsdynamisch unruhige, sich zeitlich verändernde Geschwindigkeit ein Indiz für Unfälle während der Geradeausfahrt ist. Die Wichtigkeit der minimalen und durchschnittlichen Geschwindigkeit deutet auf die Möglichkeit hin, längerfristige Aussagen bezüglich der Geradeausfahrt treffen zu können. Da diese Merkmale über unterschiedliche Zeitfenster von Bedeutung sind, muss das Klassifikationsmodell aus dem vorliegenden Geschwindigkeitsbereich einen Informationsmehrwert bezüglich der Klassifikation ziehen können.

Für Kurvenfahrten gehören erneut die kombinierten Merkmale mit Informationen zum Reibwert zu den wichtigsten. Die ständige Verfügbarkeit über alle Zeitfenster hinweg kann hier eine Rolle spielen. Das erklärt auch das höhere Niveau der Klassifikationsgüte bei Kurvenfahrten zu früheren Zeitpunkten aus dem vorherigen Abschnitt. Es ist zudem ein Anstieg der Wichtigkeit für Merkmale rein aus langsam veränderlichen Kritikalitätsmaßen bemerkbar. Diese beinhalten für alle Inputpaare eines Datensatzes identische, zeitlich nichtveränderliche Werte. Eine Klassentrennung erfolgt damit besonders bei Kurvenfahrten offensichtlich besser.

## Kritikalitätsschätzung des Fahrzustandes

In Abschnitt 5.4.1 wurde bereits ein Kritikalitätsmaß von Random Forest Modellen gezeigt, die für festgelegte Zeitfenster erzeugt und in unterschiedlichen Zeitfenstern ausgewertet wurden. Für eine kontinuierliche Auswertung im Fahrzeug eignen sich diese nicht. Da die Modelle auf einen festen Zeitbereich vor einem potentiellen Ereignis spezialisiert waren, müssten dementsprechend mehrere Modelle parallel laufend ausgewertet werden, um für verschiedene Zeitpunkte in der Zukunft Aussagen generieren zu können. Hier wird deshalb die Möglichkeit einer Klassifikation gezeigt, die mit nur einem einzigen Modell erfolgen kann. Dieses wird mit Daten verschiedener Zeitbereiche angelernt und anschließend wieder über verschiedene Zeitbereiche ausgewertet, wie es bei einer kontinuierlichen prädiktiven Kritikalitätsschätzung im Fahrzeug nötig wäre.

Damit ergeben sich die in Abb. 5.27 und Abb. 5.28 gezeigten Boxplots für die Verteilung der Kritikalität aus den Geradeaus- und Kurvenfahrten für verschiedene Zeitfensterenden. Die Darstellung unterscheidet zwischen Baseline- und Unfallsequenzen. Das obere beziehungsweise untere Quartil sowie der Median der Auswertungen definieren jeweils die Boxen. Durch die Antennen ist der 1,5-fache Abstand zwischen oberem und unterem Quartil dargestellt. Die Ausreißer werden aus Gründen der Übersichtlichkeit weggelassen. Der Wertebereich der Kritikalität erstreckt sich weiterhin von 0 bis 1. Die logarithmische Skala ist nach unten auf den Wert 0,001 begrenzt.

In beiden Abbildungen steigt für die Unfälle der Median der Kritikalität mit Annäherung an den Ereigniszeitpunkt. Demgegenüber verändert sich dieser für die Baseline-Fälle über die ausgewerteten Zeitfensterenden nur kaum und weist auch keine Steigungstendenz in Richtung Ereigniszeitpunkt auf. Die Überlappung der eingezeichneten Boxen gibt Aufschluss darüber, wie gut sich für den jeweiligen Zeitpunkt über einen Kritikalitätsschwellwert die Fälle trennen lassen.

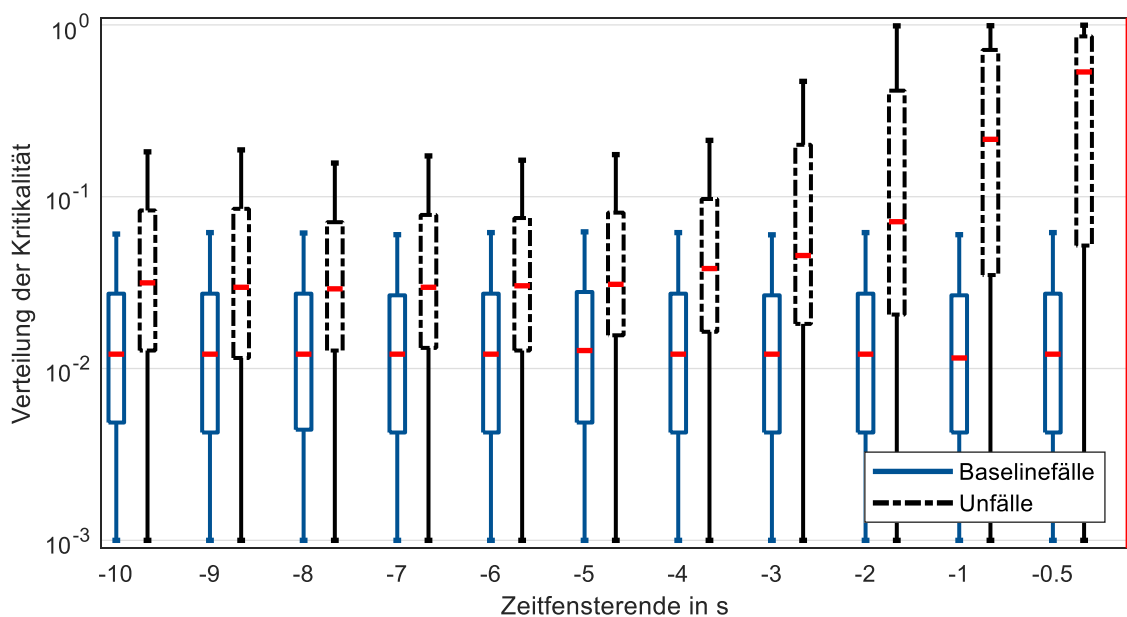


Abb. 5.27 Kritikalitätsschätzung des Fahrzustandes von Geradeausfahrten für Unfall- und Baselinedatensätze bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 62]

Bei Geradeausfahrten (Abb. 5.27) gelingt dies erst näher am Ereigniszeitpunkt im Vergleich zu den Kurvenfahrten. Speziell im Bereich 10s bis 5s vor einem Unfall ist für Geradeausfahrten kein Anstieg der Kritikalität beobachtbar. Man kann davon ausgehen, dass die zeitveränderlichen Merkmale erst kurz vor dem Unfall einen Anhaltspunkt zur Differenzierung zu Baseline-Fällen liefern. Der Einfluss der zeitlich nichtveränderlichen Merkmale bleibt über die betrachteten Zeitfensterenden eher gering und liefert im Bereich 10s bis 5s vor einem Unfall lediglich eine Tendenz zur Unterscheidung. Die Untersuchungen zur Wichtigkeit der Merkmale im vorherigen Abschnitt bestätigen diese These.

Für die Kurvenfahrten (Abb. 5.28) zeigt sich ein eindeutigeres Bild. Die Unterscheidung zwischen Baseline-Fällen und Unfällen gelingt für alle betrachteten Zeitfenster deutlich besser. Bereits 10s vor einem potentiellen Ereignis überlappen sich die Quartile von Baseline- und Unfällen fast nicht mehr. Weil sich die Verteilung für Unfälle über alle Zeitschritte hinweg weniger verändert als bei den Geradeausfahrten, scheint der Einfluss von zeitlich langsam veränderlichen Merkmalen erkennbar höher zu sein. Wiederum stützt die Untersuchung zur Wichtigkeit der Merkmale diesen Sachverhalt. Ein möglicher Schwellwert zur Auftrennung der Fälle würde sich im Diagramm als horizontale Trennlinie darstellen. Je nach Anforderungen der Anwendung kann besonders für die Kurvenfahrten schnell ein guter Kompromiss gefunden werden. Dazu passt auch, dass die zuvor untersuchte Klassifikationsgüte über alle Zeitfenster für die Kurvenfahrt höher liegt.

Es ist wichtig zu erwähnen, dass die Darstellungen stets nur die Verteilung aller ausgewerteten Fälle zeigen. Demnach existiert auch immer ein Anteil an Fällen mit falscher Kritikalitätsschätzung. Zum Beispiel gibt es Unfälle, die kurz vor dem Unfallereignis mit einer Kritikalität von  $10^{-3}$ , beziehungsweise Baseline-Fälle, die mit einer Kritikalität von 1 bewertet werden. Die Anwendung des gezeigten Verfahrens genügt demnach nicht den Ansprüchen eines irreversibel auslösenden, aktiven Fahrzeugsicherheitssystems. Zur Ergänzung eines weiteren beurteilenden Systems oder zur Vorkonditionierung scheint es hingegen geeignet zu sein.




Abb. 5.28 Kritikalitätsschätzung des Fahrzustandes von Kurvenfahrten für Unfall- und Baselinedatensätze bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 63]

### 5.4.3 Vergleich mit Support Vector Machine

Zum Methodenvergleich werden hier die Analysen für Modelle mit festgelegten Zeitfenstern vor einem Ereignis aus Abschnitt 5.4.1 anstelle von Random Forest Modellen mit einer Support Vector Machine (SVM) durchgeführt. Zuerst wird durch Variation des Zeitfensterendes die Klassifikationsgüte der SVM- mit den Random Forest- Modellen verglichen. Anschließend erfolgt die Untersuchung der wichtigsten Merkmale für SVM-Modelle unterschiedlicher Zeitfenster mit Hilfe der Wrapper-Methode. Der SVM-Algorithmus kommt jedoch, anders als der Random Forest, nicht mit undefinierten Merkmalen zurecht, weshalb unvollständige Datensätze hier nicht mit eingehen. Die Fallanzahlen verändern sich dadurch nur leicht. Es bleiben für die Geradeausfahrt 14.695 von 15.965 Datensätzen und für die Kurvenfahrt 2.861 von 3.075 Datensätzen nutzbar.

#### Klassifikationsgüte

Die Ergebnisse zum Vergleich der Klassifikationsgüte zwischen Random Forest- und SVM-Modellen zeigt Abb. 5.29. Die verwendeten Merkmale enthalten analog zum Abschnitt 5.4.1 keinen Fahrerezustand. Für die SVM-Modelle werden hierbei die Analysen für die Zeitfensterenden 10 s, 6 s, 3 s, 1 s und 0,5 s vor dem Ereigniszeitpunkt durchgeführt. Die Modellerstellung und -auswertung erfolgt erneut für sowohl Geradeaus- als auch Kurvenfahrten.

Erwartungsgemäß steigt die Klassifikationsgüte wie in vorherigen Analysen mit Annäherung an den Ereigniszeitpunkt. Die untersuchten SVM-Modelle liegen jedoch für fast alle Zeitfensterenden deutlich unterhalb der Klassifikationsgüte der Random Forest Modelle. Als Ursache hierfür ist die veränderte Durchführung der Merkmalsauswahl mit Hilfe der Wrapper-Methode durch Vorwärtsselektion denkbar. Die verbleibenden 40 beziehungsweise 45 Merkmale für Geradeaus- und Kurvenfahrten stellen gegenüber der Random Forest Anwendung eine Einschränkung dar. Die beim Random Forest in der Methode integrierte Merkmalsauswahl schafft es vermutlich, mehr unterschiedliche Merkmale in den Schätzprozess zu integrieren. Der hier für die SVM-Methode ausgewählte Merkmalsvektor besteht jeweils aus den wichtigsten Merkmalen verschiedener Zeitbereichsmodelle. Es werden damit auch Merkmale übergeben, die unter Umständen nur für bestimmte Zeitbereiche wichtig gewesen wären.




Abb. 5.29 Vergleich der Klassifikationsgüte von Support Vector Machine und Random Forest für zeitensterspezifische Modelle nach [113, S. 66]

## Wichtigkeit der Merkmale

Die Bestimmung der Wichtigkeit der Merkmale erfolgt für den SVM-Algorithmus mit Hilfe der Wrapper-Methode, die bereits zur Merkmalsauswahl verwendet wurde. Eine im Trainingsprozess integrierte Berechnung der relativen Wichtigkeiten der Merkmale wie beim Random Forest existiert hier nicht. Deshalb wird für die Modelle mit Zeitfensterenden bei -0,5s, -3s und -6s eine Vorwärtsselektion der Merkmale umgesetzt. Jede Iteration der Vorwärtsselektion bestimmt ein neues Merkmal und ordnet ihm damit einen eindeutigen Rang zu. Weil die vorgelagerte, k-fache Kreuzvalidierung einen statistischen Einfluss auf das Ergebnis haben kann, wird die Vorwärtsselektion für jedes der drei Modelle zehnmal durchgeführt. Abb. 5.30 und Abb. 5.31 zeigen die über zehn Wiederholungen gemittelten Ränge der Merkmale für Geradeaus- und Kurvenfahrten. Die enthaltenen Merkmale gehören in mindestens einem der Modelle zu den acht wichtigsten. Merkmale aus ähnlichen Signalen beziehungsweise Erzeugungsmethoden sind zur Veranschaulichung wiederum möglichst zusammen aufgeführt.

Im direkten Vergleich zur Wichtigkeit der Merkmale beim Random Forest fällt die höhere Bedeutung der Merkmale aus den Radarsensordaten auf. Die Ursache kann hier das Vorgehen der Wrapper-Methode sein, die sekundäre, begleitende Merkmale sichtbar häufiger als immer vorhandene auswählt. Ähnliche Merkmale bekommen dabei nicht immer einen ähnlich hohen Rang zugewiesen. Durch das schrittweise Hinzufügen von Merkmalen wird nach dem Auswählen eines Merkmals die Wahl eines ähnlichen Merkmals unwahrscheinlicher, weil andersartige Merkmale das Klassifikationsergebnis in den nächsten Iterationen stärker verbessern können. Die wichtigen Merkmale stammen somit aus mehr unterschiedlichen Erzeugungskategorien als beim Random Forest.






Abb. 5.30 Wichtigkeit der Merkmale für Geradeausfahrten bei zeitensterspezifischen SVM-Modellen nach [113, S. 67]

Für Geradeausfahrten sind besonders kombinierte Merkmale verschiedener Kategorien dominant. Das Merkmal „mean(v)\_OR\_Reibwert“ aus der Fahrzeuggeschwindigkeit und dem vorliegenden Reibwert erreicht sogar bei allen drei untersuchten Modellen die höchste Wichtigkeit. Es kann als Eigenschaft des Fahrzustandes interpretiert werden, die stark mit dem vorliegenden, möglichen Anhalteweg skaliert und damit die längsdynamische Handlungsfähigkeit beschreibt. Die Informationen zur direkten vorderen Fahrzeugumgebung werden ebenso als wichtig eingestuft. Zugehörige Merkmale basieren auf den Abstandsmaßen aTTC und Distanzreserve oder der Existenz von seitlichen oder frontalen Objekten.

Darüber hinaus ist die erhöhte Wichtigkeit von Merkmalen aus der Vertikalbeschleunigung auffällig. Ein direkter physikalischer Zusammenhang zur Fahrzeuglängsdynamik fehlt hier. Jedoch können stark schwankende Radaufstandskräfte die Bodenhaftung verringern und damit kritische Brems- oder Ausweichmanöver erschweren [140, S. 543]. Weitere mögliche Erklärungen könnten Aufbaubeschleunigungen bei hoher Geschwindigkeit oder Nickbewegungen des Fahrzeugs durch Längsbeschleunigung oder -verzögerung sein. Eine zusätzliche Besonderheit stellt das Auftreten von Merkmalen aus Gierratenänderungen vor allem für das Modell 6s vor einem potentiellen Ereignis dar. Denkbare Interpretationen wären eine erhöhte Komplexität der Fahraufgabe oder eine eingeschränkte Sichtweite durch eine vorhergehende Kurvendurchfahrt. Dieser Aspekt müsste durch weiterführende Analysen belegt werden.

Bei den Kurvenfahrten lassen sich für Modelle aller Zeitbereiche keine eindeutigen, gemeinsamen Beobachtungen machen. Das Modell mit Zeitfensterende 0,5s vor dem Ereignis zeigt eine hohe Wichtigkeit von Merkmalen aus fahrzeugkinematischen Signalen mit Beteiligung der Längs- oder Querbeschleunigung. Wie zuvor bei den Geradeausfahrten hat ein kombiniertes Merkmal aus einer fahrzeugkinematischen Größe (hier std(a\_y)) und dem Reibwert den höchsten Rang. Da das Merkmalzeitfenster bereits kurz vor dem Ereignis liegt, kann das Vorliegen einer hohen Querdynamikänderung als Notausweichmanöver bei auffälligem Reibwert mit Tendenz zum Schleudern gedeutet werden. Bereits bei den Geradeausfahrten zeigte dieses Merkmal im beschriebenen Zeitfenster eine erhöhte Wichtigkeit.




Abb. 5.31 Wichtigkeit der Merkmale für Kurvenfahrten bei zeitfensterspezifischen SVM-Modellen nach [113, S. 68]

Für das Modell mit Zeitfensterende 3 s vor dem Ereignis verschiebt sich der Fokus der Merkmale stärker in Richtung des Fahrzeugumfeldes. Neben der weiterhin dominanten Fahrzeuglängsbeschleunigung finden besonders Merkmale aus Abstandsmaßen zum Vorderfahrzeug in Form der TTC, der Zeitlücke THW oder der direkten Distanz zum nächsten Objekt Anwendung. Wie bereits bei den Geradeausfahrten zählt die Vertikalbeschleunigung zum erweiterten Merkmalskreis, hier in Form der diskreten Fouriertransformation für Frequenzen zwischen 3 und 5 Hz.

Im Gegensatz zu den Modellen mit Zeitfensterende 0,5 s und 3 s vor dem Ereignis treten beim Modell 6 s vor dem Ereignis keine außerordentlich auffälligen Merkmale mehr auf. So besitzt keines einen durchschnittlichen Rang unter 10. Eine mögliche Interpretation wäre der mit größerem Zeitabstand sinkende, kausale Zusammenhang zwischen Merkmalsinformationen und Ereignis. Im Kontext der hierarchischen Wichtigkeit der Ränge gewinnen umfeldbasierte Merkmale weiter an Bedeutung. Neben den bereits erwähnten Abstandsmaßen zu einem Vorderfahrzeug kommen unkonkretere Merkmale aus der Anzahl von Objekten deutlicher zum Vorschein.

An den Ergebnissen zur Wichtigkeit wird ersichtlich, dass zur Interpretation von einzelnen Merkmalen weitere Untersuchungen möglich wären. Die Wichtigkeit in Form einer Rangtabelle spiegelt einen Zusammenhang für eine verbesserte Schätzung wider. In diesem Fall wird aber noch keine genauere Aussage zur Assoziation zwischen Kritikalität und Merkmal gemacht. Besonders bei den Merkmalen aus zeitveränderlichen Größen würden statistische Assoziationsmaße wie die Kovarianz weiterführende Erklärungen liefern. Damit wären Aussagen zur Richtung der Beziehung, die von positiver oder negativer Relation bis hin zu vollständiger Unabhängigkeit reichen kann, möglich.

# 6 Diskussion und Ausblick

Dieses Kapitel ordnet die in Abschnitt 5.4 gezeigten Ergebnisse bezüglich der gestellten Forschungsfragen (6.1) und der verwendeten Datenbasis (6.2) ein. Zudem erfolgt ein Ausblick zur Weiterverwendung des mit der Methode generierten Informationsmehrwertes (6.3.1) und dem Transfer der Methode auf andere Fragestellungen (6.3.2).

## 6.1 Einordnung der Ergebnisse bezüglich der gestellten Forschungsfragen

Die in Abschnitt 3.1 hergeleiteten Forschungsfragen sollen abschließend hinsichtlich des entwickelten Vorgehens und der gezeigten Ergebnisse beantwortet werden.

### Beantwortung von Forschungsfrage 1

#### **Kann der Zielkonflikt aus Datentiefe und Fallanzahl durch die Nutzung einer großen NDS aufgelöst werden?**

Der Zielkonflikt kann durch die Nutzung der SHRP2 NDS nicht vollständig aufgelöst werden. Die enthaltene Datentiefe ist durch die aufgezeichneten Fahrkinematiksignale und Radarsensordaten sowie den aufwändigen Labelprozess von langsam veränderlichen Einflussfaktoren gleichwertig zu bisherigen Datenbanken aus anderen Studien. Durch den großen Studienumfang sind hier jedoch auch Unfälle enthalten. Bisherige Untersuchungen stützen sich in Ermangelung von Unfällen rein auf Beinaheunfälle. Die Unfallanzahl der SHRP2 Daten genügt, um für Geradeaus- und Kurvenfahrten eine exemplarische Kritikalitätsschätzung durchführen zu können. Hierbei ist zu erwähnen, dass zur Erhöhung der Fallanzahl in die Gruppe der Kurvenfahrten auch Abbiegeszenarien aufgenommen wurden (Kap. 5.3.2). Zur Untersuchung anderer Manöver- respektive Unfalltypen ist die Fallanzahl jedoch zu gering. Die Nutzung der Kundenfahrzeugflotte eines großen OEM (jährliche Fahrzeugabsatzzahl  $>10^6$ ) zur Datengewinnung würde innerhalb weniger Monate den Umfang der SHRP2 NDS (80 Mio. km) übertreffen und könnte damit den Zielkonflikt signifikant verbessern (Kap. 4.5.2).

### Beantwortung von Forschungsfrage 2

#### **Kann durch ausschließliche Nutzung und Vergleich von unkritischen Fahrsequenzen (genannt Baseline) mit Unfallsequenzen einer angemessenen Unfallschwere das Validierdilemma umgangen werden?**

Ein Unfall angemessener Schwere gilt in jedem Fall als kritisch, was bei allen denkbaren Vorstufen von Beinahe- beziehungsweise leichten Unfällen nicht immer der Fall ist. Die gemachte

Untersuchung vergleicht angemessen schwere Unfälle mit unkritischen Sequenzen und umgeht damit die Beweisschuld, ob ausreichende Kritikalität vorlag. Die identifizierten Merkmale dienen dazu, unkritische Fahrsequenzen von Unfallsequenzen unterscheiden zu können. Die Analyse, wie gut die erstellten Schätzmodelle zwischen Beinahe-Unfällen und Unfällen trennen können, fehlt bewusst in der vorliegenden Arbeit. Dieser Aspekt müsste in künftigen Forschungen untersucht werden.

### **Beantwortung von Forschungsfrage 3**

#### **Lassen sich langsam veränderliche Einflussfaktoren für eine bessere Schätzung der Kritikalität in den Prädiktionsprozess integrieren?**

Der vorgestellte Ansatz nutzt Maschinenlernverfahren zur prädiktiven Schätzung der Kritikalität. Damit ist es möglich, über erzeugte Merkmale Informationen verschiedener Datenquellen miteinzubeziehen. Die in Kapitel 4 quantifizierten, langsam veränderlichen Kritikalitätsmaße lassen sich nach einer Datenvorverarbeitung (Kap. 5.2.2) und Merkmalerzeugung (Kap. 5.3.3) somit direkt in den Prädiktionsprozess integrieren. Es wurde gezeigt, dass die Schätzungsgüte mit Hinzunahme der langsam veränderlichen Einflussfaktoren ansteigt, wie Abb. 5.22 am Beispiel der Fahrerzustandsinformation zeigt. Darüber hinaus ist die Integration nur sinnvoll, wenn die zugrundeliegenden Daten beider Analysen auf der gleichen oder zumindest sehr ähnlichen Datenbasis aufbauen. Der Transfer der Einflussfaktoren einer beliebigen Unfalldatenbank in ein anderes Fahrzeug-Fahrer-Kollektiv ist damit nicht möglich.

### **Beantwortung von Forschungsfrage 4**

#### **Lässt sich durch Maschinenlernverfahren retrospektiv der „Erfahrungswert“ aus Sequenzen einer Unfalldatenbank inklusive zugehöriger Baseline-Daten zur Unfallprädiktion nutzen?**

Die Modelle aus Maschinenlernverfahren nutzen implizit während des Erstellprozesses die über Merkmale quantifizierten Gegebenheiten vor einem Unfall zum Lernen einer Unfallprädiktion. Die anschließende Auswertung der Modelle verwendet diese gemachte „Erfahrung“ zur Klassifikation. Unter der Annahme, dass ein Anteil der Unfälle in ähnlichen Konstellationen schon einmal stattgefunden hat und auch weiter stattfinden wird, kann hier ein Maschinenlernverfahren mit ausreichender Datenbasis die künftigen, ähnlichen Unfälle prädiktiv vorhersagen.

### **Beantwortung der Forschungsfragen 5, 6 und 7**

#### **Lässt sich ein Zusammenhang zwischen der erreichbaren Kritikalitätsschätzungsgüte und der Prädiktionszeit für hinreichend weite Zeiträume herleiten?**

**Kann man zuverlässig 3 s bis 5 s vor einem Unfall diesen erkennen und den Fahrer warnen?**

**Kann die Wichtigkeit der Einflussfaktoren einer Kritikalitätsschätzung für unterschiedliche Prädiktionszeiträume bestimmt werden?**

Die Arbeit stellt einen Zusammenhang zwischen Schätzungsgüte und Prädiktionszeitraum her. Es wird gezeigt, dass eine Kritikalitätsschätzung auch über Zeiträume von wenigen Sekunden

hinaus eine nutzbare Schätzgüte erreichen kann. Die durchgeführten Prädiktionen reichen bis zu 10s vor einem möglichen Unfallereignis. Insbesondere die langsam veränderlichen Kritikalitätsmaße, die über Merkmale in den Schätzprozess integriert wurden, führen zu einer klaren Verbesserung der Güte im Zeitraum zwischen 3s und 10s vor einem potentiellen Ereignis.

Die Nutzbarkeit der Schätzmodelle wird dazu noch in Kap. 6.3.1 am Beispiel Geradeausfahrten für verschiedene Auslöseschwellen der prädizierten Kritikalität dargestellt. Es zeigt sich, dass die Detektion eines Unfalls 3 s bis 5 s vorher einem Kompromiss zwischen falsch positiven Fällen (Falschalarm) und falsch negativen Fällen (fälschlicherweise ausbleibender Alarm) unterworfen ist. Die sich ergebenden Verhältnisse rechtfertigen keine direkte Fahrerwarnung. Viel sinnvoller ist demnach die Verwendung des Informationsmehrwerts zur Vorkonditionierung von aktiven Sicherheitssystemen oder zur vorrauschauenden Verhaltensanpassung im automatisierten Fahrbetrieb.

Die Untersuchung der Wichtigkeit der Merkmale bestätigt diesen Sachverhalt. Zum einen wurde die Bedeutung von fahrzeugkinematischen Signalen und Umfeldinformationen im Zeitraum von 0s bis 3s vor einem Unfall aufgezeigt. Zum anderen waren besonders für die Zeitfenster von 3s bis zu 10s vor dem potentiellen Ereignis die Merkmale aus langsam veränderlichen Kritikalitätsmaßen beziehungsweise kombinierte Merkmale mit Anteilen daraus dominant. Die Ergebnisse motivieren zu einem Einbeziehen dieser Informationen in den Entscheidungsprozess aktiver Fahrzeugsicherheitssysteme.

## 6.2 Einordnung der Ergebnisse bezüglich der verwendeten Datenbasis

Die Datenqualität der verwendeten SHRP2 Studie erwies sich als dürftig. Zum Teil mussten Zeitreihensignale rekonstruiert oder sogar komplette Sequenzen aussortiert werden (Kap. 5.2.1). Die Ursache hierfür liegt vermutlich in der durchgeführten Nachrüstung des Messaufbaus. Insbesondere die Radarsensordaten, die als einzige Informationsquelle zum Fahrzeugumfeld zur Verfügung standen, sind lückenhaft und entsprechen nicht dem Stand der Technik heutiger Serienfahrzeuge. Diese sichern die Umfeldwahrnehmung durch mehrere redundante Sensoren ab und können bereits klassifizierte Objekte inklusive deren Ausdehnung zur Verfügung stellen.

Ebenso gestaltete sich die Datenkonsistenz der Studie als schwierig. Da verschiedene Fahrzeugklassen beteiligt waren (Limousine, Pickup/Truck, SUV/Crossover, Van/Minivan), ergibt sich folglich eine unterschiedliche Fahrdynamik [20]. Die vorliegende Fahrzeugklasse war im Datensatz nicht enthalten und konnte dementsprechend auch nicht berücksichtigt werden [95]. Es lag zudem keinerlei Information zur Ausrüstung mit ESP vor. Damit ergeben sich im Hinblick auf die fahrzeugkinematischen Signale heterogene Zusammenhänge. Diese sind deshalb durch einen automatisierten Algorithmus schwieriger zu untersuchen.

Die Generalisierbarkeit bezeichnet die Anwendung eines aus historischen Daten angelernten Modells auf aktuelle, kontinuierlich in einem Fahrzeug vorliegende Daten. Diese Transferleistung eines maschinellen Lernsystems funktioniert erst mit vielen gelernten Beispielsequenzen inklusive Unfällen. Nur dann enthält der genutzte Lerndatensatz genug ähnliche Beispiele, um wirklich bedeutend viele Unfälle prädizieren zu können. Selbst die hier verwendete NDS, die bislang als die größte ihrer Art gilt, reichte nach Aufteilung in Manöver nur für die weitere Analyse von Geradeaus- beziehungsweise Kurvenfahrten aus. Für die Umsetzung einer derartig

datenetriebenen, prädiktiven Kritikalitätsschätzung ist demnach zuerst eine ausreichende Datensammlung nötig. Der Datenschutz der Fahrer muss jedoch weiterhin durch geeignete Konzepte in jeglicher Hinsicht gewahrt werden.

Alle genannten Nachteile wären für einen großen OEM jedoch zu bewältigen (Kap. 4.5.2). Eine angenommene Datensammlung über mehrere Modellreihen hinweg könnte eine vergleichbar große Datenbasis mit 80 Mio. Fahrzeugkilometern in kurzer Zeit erreichen. Ebenso wäre die Datenqualität insbesondere der Umfeldwahrnehmung stark verbessert sowie das zugrunde liegende Fahrzeugkollektiv homogener. Der Umfang der zu erfassenden Signale orientiert sich an den einflussreichen, langsam veränderlichen Kritikalitätsmaßen (Kap. 4.4) sowie den wichtigen gezeigten Merkmalen (Kap. 5.4). Neben den hier verwendeten Daten würde ein Kamerabild der vorderen Fahrzeugumgebung zusätzliche Kontextinformationen zur Situation liefern. Eine ortsbezogene Erhebung und Auswertung könnte darüber hinaus noch auf örtliche Besonderheiten eingehen. Unter den genannten Prämissen ist eine höhere Prädiktionsgüte als in der vorliegenden Arbeit zu erwarten.

## 6.3 Ausblick

Dieser Abschnitt beschreibt Möglichkeiten, wie die Erkenntnisse der vorliegenden Arbeit künftig Anwendung finden können. Die Weiterverwendung des Informationsmehrwerts einer prädiktiven Kritikalitätsschätzung wird sowohl allgemein als auch anhand eines Anwendungsfalls vorgestellt (Kap. 6.3.1). Anschließend folgt ein möglicher Transfer der Methode auf andere Fragestellungen der Fahrzeugtechnik (Kap. 6.3.2).

### 6.3.1 Weiterverwendung des Informationsmehrwerts

Die prädiktive Kritikalitätsschätzung über mehrere Sekunden in die Zukunft verschafft aktiven Sicherheitssystemen einen zeitlichen Vorteil. Bereits eine um 0,5 s frühere Fahrreaktion besitzt das Potential, die Hälfte aller Querverkehrs- und Auffahrkollisionen zu vermeiden [7]. Eine um mehrere Sekunden frühere Reaktion ist dementsprechend in der Lage, einen Großteil der Unfälle abzuwenden. Die Intensität des aktiven Sicherheitseingriffs hängt auch direkt mit dem Eingriffszeitpunkt vor dem kritischen Ereignis zusammen. So kann bereits eine geringfügige Fahrverhaltensanpassung wie die Vergrößerung des Abstandes zum Vorderfahrzeug oder eine leicht verringerte Kurvengeschwindigkeit eine starke Auswirkung auf den weiteren Verlauf der Verkehrssituation haben.

Ein Nachweis der Wirkung solcher unauffälligen Eingriffe ist jedoch nur schwer zu erbringen. Im Gegensatz zur Aktivierung eines Notbremsassistenten, der direkt einer latenten Gefahr zugeordnet ist, kann hier der kausale Zusammenhang zu einem potentiellen Unfallgegner nicht nachgewiesen werden. Die einzige Möglichkeit bietet nur ein langfristiger Vergleich von Unfallhäufigkeiten. Aus ähnlichen Gesichtspunkten kann der Informationsmehrwert auch nicht in Form einer Fahrerwarnung erfolgen. Eine logische Verknüpfung zwischen prädizierter Gefahr und Warnung ist für diesen möglicherweise nicht zu bewältigen. Insofern scheint ein unaufdringlicher Hinweis sinnvoller.

Die im Abschnitt 5.4 vorgestellten Klassifikationsmodelle wurden bisher rein nach ihrem ROC-AUC Gütemaß quantifiziert. Ausgehend von einer derartigen ROC-Kurve soll hier für mehrere denkbare Anwendungsfälle eine beispielhafte Auslegung gezeigt werden. Jede Wahl eines

Punktes der ROC-Kurve ergibt ein festes Verhältnis zwischen korrekten Schätzungen und falsch positiven beziehungsweise falsch negativen Fällen. Die Werte führen zu Konfusionsmatrizen und veranschaulichen damit den Kompromiss einer prädiktiven Klassifikation (Abb. 6.1). Die Senkung von falsch positiven Fällen (Falschalarme) führt unweigerlich zu einer Erhöhung von falsch negativen Fällen (fälschlicherweise ausbleibender Alarm). Die Werte der ROC-Kurve stammen vom kontinuierlich schätzenden Random Forest Modell für Geradeausfahrten aus Abschnitt 5.4.2. Sie wurden für Datensätze aller in der Arbeit betrachteten Zeitfenster von 0s bis 10s vor einem Ereignis angelernt und ausgewertet.

Je nach Anwendungsfall könnte dieses Modell auch nur für ein kürzeres Zeitfenster wie beispielsweise von 0s bis 5s vor einem potentiellen Unfall erstellt und getestet werden. Nach den Untersuchungen zum Einfluss des Zeitbereichs auf die Schätzgüte (Kap. 5.4) steigt demzufolge die Klassifikationsperformance, was sich in einer höher liegenden ROC-Kurve

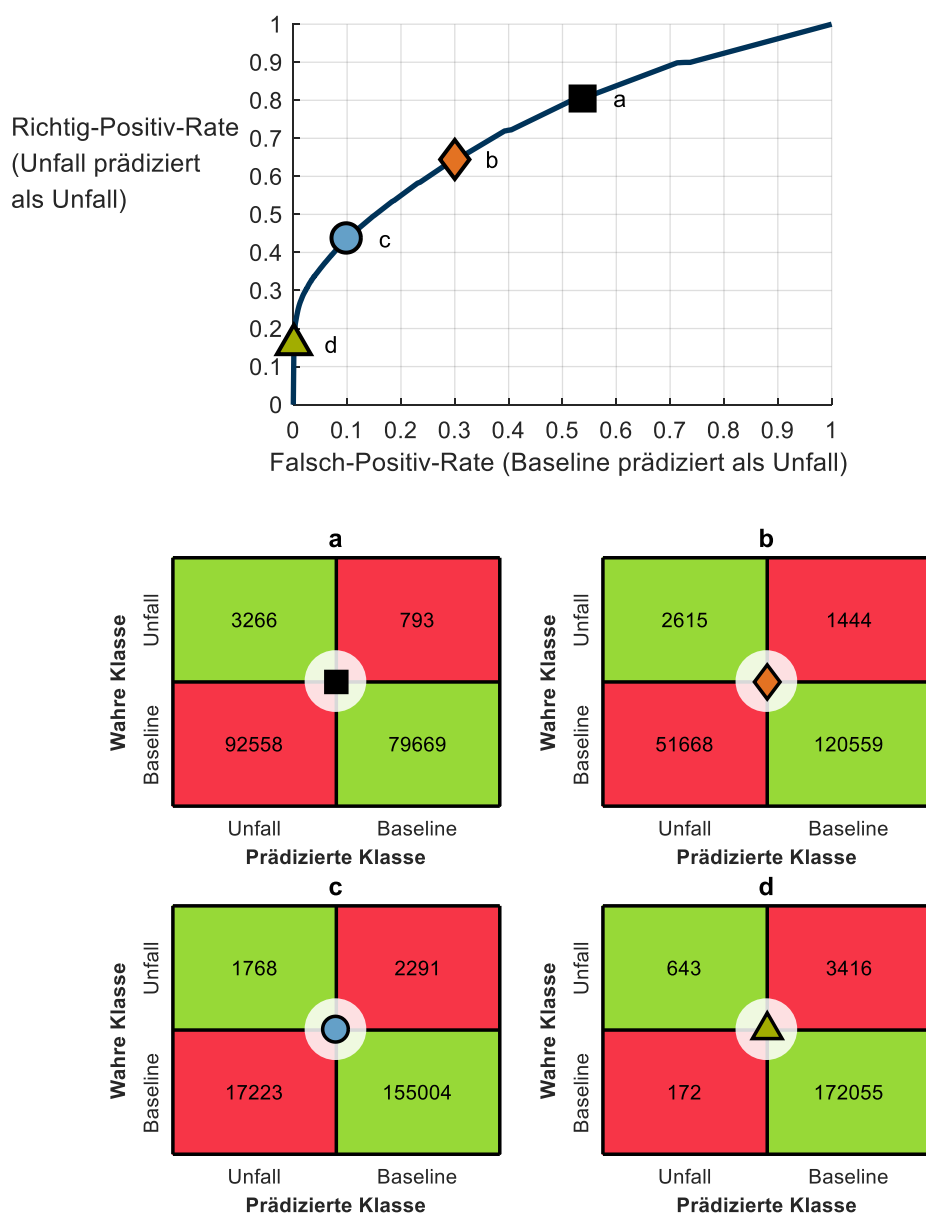


Abb. 6.1 ROC-Kurve für Geradenausfahrten mit Schwellwerten der Kritikalität für Inputpaare von 0s bis 10s vor einem potentiellen Unfall (oben) und zugehörige Konfusionsmatrizen (unten) nach [113, S. 64]

widerspiegeln würde. Damit ginge eine Verbesserung des Kompromisses zwischen Falsch-auslösungen und fälschlicherweise ausbleibenden Auslösungen einher. Es ist wichtig zu erwähnen, dass rein das geschätzte Kritikalitätsniveau genutzt wird und keinerlei Information zur verbleibenden Zeit vor einem Ereignis vorliegt. Die Schätzmodelle besitzen durch die Gestaltung der verwendeten Merkmale kein Wissen zum zugrundeliegenden Zeitbereich, indem sie erzeugt wurden.

Je nach gewählten Schwellwerten der Kritikalität, symbolisiert durch die Punkte a, b, c und d, ergibt sich eine andere Charakteristik in den Konfusionsmatrizen, die jeweils andere Wirkbereiche ermöglicht. In den Boxplots Abb. 5.27 und Abb. 5.28 ließe sich ein derartiger Kritikalitätsgrenzwert als horizontale Trennlinie zwischen Baseline-Fälle und Unfällen veranschaulichen.

Denkbare Fahrerassistenzsysteme, die davon profitieren könnten, sind alle aktiven, die Längs- oder Querdynamik beeinflussenden Funktionen. Hierbei liegt der Fokus nicht auf den irreversiblen Funktionen zur Unfallschwereminderung, sondern vielmehr auf Geschwindigkeitsregelautomaten, vorausschauenden Notbremsassistenten oder der Manöverplanung. Diese können mit Kenntnis der aktuellen Kritikalitätsstufe ihr Verhalten stufenweise adaptiv gestalten. Damit besteht die Möglichkeit, kritische Situationen durch das angepasste Verhalten prädiktiv zu vermeiden oder Auslösefehler (falsch positiv und falsch negativ) zu minimieren.

Der Ansatz betrachtet aktuell nur Korrelationen zwischen Merkmalen und auftretenden Unfällen. Eine Weiterentwicklung könnte in der Herleitung von kausalen Zusammenhängen in den Zeitreihen bestehen, die damit eine Art der Erfahrungsweitergabe über mehrere Zeitfenster ermöglicht. Dies wäre beispielsweise mit rekurrenten beziehungsweise rückgekoppelten, künstlichen neuronalen Netzen möglich [115, S. 568]. Eine weitere Möglichkeit besteht in der Verwendung von Deep Learning Methoden. Der Lernalgorithmus erzeugt hier implizit die Merkmale [141, S. 5]. Damit wären kombinierte Merkmale nicht mehr den festgelegten Regeln des Entwicklers unterworfen. Deep Learning Methoden erlauben zudem mit der Verarbeitung von Videobildern zusätzliche Kontextinformationen in den prädiktiven Schätzprozess einzubeziehen. Ungeachtet davon können die Informationen zu langsam veränderlichen Kritikalitätsmaßen weiterhin als Eingangsgrößen dienen.

### 6.3.2 Transfer der Methode auf andere Anwendungsfälle

Die Methode lässt sich auch auf andere Disziplinen übertragen. Jeder Ansatz basiert weiterhin auf einer Datenbank mit aufgezeichneten Fahrten im Straßenverkehr. Einzig das zu untersuchende Anwendungsfeld, die Art der verwendeten Daten und die Zielvariable variieren hierbei. Tabelle 6.1 präsentiert einige mögliche Ansätze. Es ist zu beachten, dass die Modellbildung mit maschinellen Lernmethoden offline durchgeführt werden kann, die Schätzung und Auswertung der Modelle kann anschließend wieder online im Fahrzeug erfolgen.

Ein denkbarer Ansatz bezieht sich auf die Optimierung der Fahrdynamikregelung. Aus Fahrdynamikdaten inklusive der fahrstreifengenauen Lokalisierung könnten Modelle erzeugt werden, die Komfort- oder Performancemaße prädizieren und damit eine optimale Fahrwerksregelung ermöglichen.



Tabelle 6.1 Transfer der Methode auf andere Anwendungsfälle

Anwendungsfeld	Art der verwendeten Daten	Zielvariable	Ziel
Fahrdynamikoptimierung	IMU Signale, GPS, Fahrwerksignale	Komfort- oder Performancemaß	Prädiktive Fahrwerksregelung
Fahrerzustandsschätzung	Innenraumsensorik	Müdigkeit, Ablenkung, Gesundheitszustand	Prädiktive Aufmerksamkeitssteuerung, Fahrpausenempfehlung, Übernahmezeitabschätzung
Umfeldwahrnehmung	Umfeldsensoren	Verhaltensschätzung von Verkehrsteilnehmern	Prädiktion einer Fahrsituation
Automatisierte Fahrfunktionen	Umfeldsensor-signal, Fahrdynamik	Systemzustände automatisierter Fahrfunktionen	Prädiktive Abschätzung von Systemgrenzen oder kritischen Systemzuständen, Verfügbarkeitsgrenze der Fahrfunktionen

Der Zusammenhang zwischen Fahrerzustandssensorik und Fahrerzustandsschätzung lässt sich nur schwer mit festen Abhängigkeiten abbilden [142][143]. Eine aufgezeichnete Datenbasis mit aufwändiger Fahrersensorik ließe sich nach Messung einer gewünschten Fahrervariable dazu verwenden, den Zusammenhang zwischen seriennaher Fahrersensorik und dieser Fahrervariablen mit Modellen des maschinellen Lernens abzubilden. Das Modell wäre in der Lage, prädiktiv einen Fahrerzustand zu schätzen, der wiederum in Funktionen wie einer Aufmerksamkeitssteuerung, einer Fahrpausenempfehlung oder während der hochautomatisierten Fahrt einer dynamischen Übernahmezeitabschätzung einfließen könnte.

Die prädiktive Umfeldwahrnehmung ist häufig großen Abhängigkeiten und kausalen Verhaltenswechselbeziehungen zwischen einzelnen Verkehrsteilnehmern ausgesetzt. Diese lassen sich aufgrund der Komplexität nur schwer in gewöhnlichen Modellen abbilden. Ein auf maschinellem Lernen basierender Ansatz könnte diesen Zusammenhang anhand vieler ähnlicher, aufgezeichneter Beispielsituationen erfassen und prädiktiv im Fahrzeug wieder zur Verfügung stellen.

Systemzustände hochautomatisierter Fahrfunktionen unterliegen vielen kombinierten Einflüssen wie wechselnden Güten der Umfeldwahrnehmung oder unterschiedlichen Verkehrssituationen. Diese wirken sich auf die Sicherheit und Verfügbarkeit der angebotenen hochautomatisierten Fahrfunktion aus. Die Fahrzeughersteller versuchen dem mit statischen Verfügbarkeitsgrenzen beizukommen. Eine dynamische, prädiktive Verfügbarkeitsgrenze abhängig von Ort, Zeit, Fahrzustand, Fahrumgebung und aktuellem Systemzustand wäre in der Lage, den Kompromiss aus Kundennutzen und Haftungsrisiko besser zu lösen. Für höhere Automatisierungsgrade könnte der gewonnene Informationsmehrwert wie bereits erwähnt zur Fahrverhaltensanpassung verwendet werden (Kap 6.3.1).



# 7 Zusammenfassung

*“The cleverest algorithms are no substitute for human intelligence and knowledge of the data in the problem.”* Leo Breiman

Die vorliegende Arbeit zeigt eine Methodik zur prädiktiven Schätzung der Kritikalität in einem Fahrzeug mit Hilfe von Maschinellen Lernverfahren, die retrospektiv mit Hilfe von Beispielsequenzen aus einer Datenbasis von Fahrten im Straßenverkehr Schätzmodelle bilden. Diese können anschließend in einem Fahrzeug kontinuierlich ausgewertet werden und für Zeitfenster bis zu 10s in die Zukunft vor einem potentiellen Unfall eine Aussage zur Kritikalität des Fahrzeugzustandes liefern. Wesentlich hierbei ist die Integration von langsam veränderlichen Kritikalitätsmaßen in den Schätzprozess. Über Merkmalsbildung können dadurch beispielsweise Informationen des Fahrerzustandes, der Fahrbahnbeschaffenheit oder des Wetters in die Prädiktion einfließen.

Trotz steigender Einbauraten von Fahrerassistenzsystemen in den letzten Jahren sanken die Unfallzahlen nicht weiter. Daraus entstand die Motivation, alle verfügbaren Daten in der Situationsbewertung für aktive Fahrzeugsicherheitssysteme zu berücksichtigen, um noch früher Unfälle vorhersehen zu können. Besonders mit der Möglichkeit eines früheren, aktiven Eingriffs in die Fahrdynamik könnten deutlich mehr Unfälle vermieden werden als bisher.

Der Stand der Wissenschaft diskutierte dazu alle verfügbaren Daten von Fahrten im Straßenverkehr, stellte Möglichkeiten zur Extraktion relevanter Szenarien und zur Bewertung der Kritikalität derselben vor. Weiterhin wurden Methoden und Ergebnisse zur retrospektiven Bestimmung von langsam veränderlichen Kritikalitätsmaßen aus Unfalldatenbanken und Studiendaten erläutert. Möglichkeiten zur prädiktiven Schätzung einer Unfallwahrscheinlichkeit aus schnell veränderlichen Einflussfaktoren wurden abschließend dargelegt. In einer folgenden Diskussion des Stands der Wissenschaft konnten Forschungsfragen hergeleitet werden, die in die Vorstellung der Idee dieser Arbeit sowie deren Aufbau mündeten.

Der erste Teil der Methodik basiert auf Fahrsequenzen mit der Dauer von 30s aus der naturalistischen Fahrverhaltensstudie SHRP2. Die Sequenzen können sowohl in einem Unfall als auch vollkommen unkritisch enden. Die zu jeder Sequenz gehörigen Eventdaten enthalten Informationen zum gefahrenen Fahrmanöver, dem Fahrer und der Fahrzeugumgebung. Aus diesen ließen sich über eine Odds Ratio Analyse langsam veränderliche Kritikalitätsmaße berechnen. Selbige stellen für jede Ausprägung, wie beispielsweise dem Vorliegen einer nassen Straße, quantitativ den jeweiligen Einfluss auf die Unfallwahrscheinlichkeit dar. Die Ergebnisse wurden in den darauffolgenden Schritt der prädiktiven Kritikalitätsschätzung integriert. Sie können aber für sich bereits eine grobe, prädiktive Aussage zur Kritikalität des Fahrzeugzustandes liefern.

Die prädiktive Kritikalitätsschätzung bildete zuerst aus den Zeitreihensignalen der Sequenzen sowie aus den zuvor berechneten langsam veränderlichen Kritikalitätsmaßen entscheidungsrelevante Merkmale, die zur Klassifikation zwischen Unfall- und unkritischen Sequenzen

verwendet werden können. Die Untersuchung fokussierte sich hier auf die Manövertypen Geradeaus- sowie Kurvenfahrt. Als geeignete maschinelle Lernverfahren wurden der Random Forest sowie die Support Vector Machine identifiziert. Diese ermöglichten die Erstellung von Modellen, die anhand von Merkmalen aus einem definierten, dem Modell zugehörigen Zeitfenster vor einem potentiellen Unfall eine Klassenzuordnung schätzen. Durch Variation der Merkmalszusammenstellung, des betrachteten Zeitfensters und der verwendeten Methode konnten Aussagen zur Klassifikationsgüte, zur Wichtigkeit der Merkmale sowie zur geschätzten Kritikalität des Fahrzustandes hergeleitet werden.

Es zeigte sich, dass die Klassifikationsgüte wie erwartet mit zeitlicher Nähe zum potentiellen Ereigniszeitpunkt ansteigt. Außerdem führte die Verwendung der Fahrerzustandsinformation in den Merkmalen zu einer höheren Klassifikationsgüte. Des Weiteren waren für jedes betrachtete Zeitfenster andere Merkmale für die Klassifikation ausschlaggebend. Wohingegen kurz vor dem möglichen Unfall Merkmale aus den dynamischen Zeitreihendaten wie Beschleunigungen als wichtig identifiziert wurden, erwiesen sich für längere Prädiktionszeiträume zusätzlich die Informationen aus den statischen Kritikalitätsmaßen als entscheidend. Im Fall einer kontinuierlichen Kritikalitätsschätzung, die sich als eine Art Wahrscheinlichkeit zur Klassenzuordnung versteht, wurde als Sonderfall ein einzelnes Modell in mehreren Zeitfenstern ausgewertet. Hier zeigte sich wie bei den Analysen mit mehreren, den Zeitfenster zugeordneten Modellen, ein Anstieg der Klassifikationsgüte mit zeitlicher Nähe zum potentiellen Ereigniszeitpunkt.

Die vorgestellte Methode liefert eine prädiktive Aussage zur Kritikalität eines Fahrzustandes über mehrere Sekunden, die von aktiven Fahrzeugsicherheitssystemen weiterverwendet werden kann. Der gewonnene Informationsmehrwert ermöglicht für reversible, aktive Sicherheitssysteme frühere Auslösungen, die dadurch weniger starke Eingriffe in die Fahrdynamik benötigen. Zusätzlich ist bei automatisierten Fahrfunktionen eine vorausschauende Verhaltensanpassung denkbar. Die erreichbare Güte einer prädiktiven Schätzung hängt vom betrachteten Fahrmanöver sowie der verfügbaren Datenqualität und Fallanzahl der zugrundeliegenden Datenbasis ab. Die vorliegenden, erzielten Ergebnisse dieser Arbeit zeigen trotz der geringen Datenqualität vielversprechende Ansätze und liefern Ideen für künftige datenbasierte Sicherheitssysteme.

*Die Ergebnisse und Schlussfolgerungen dieser Arbeit sind die des Autors und repräsentieren nicht notwendigerweise die Ansichten des VTTI (Virginia Tech Transportation Institute), dem Transportation Research Board oder der National Academies.*

*The findings and conclusions of this thesis are those of the author and do not necessarily represent the views of VTTI, the Transportation Research Board, or the National Academies.*



# Abbildungsverzeichnis

Abb. 1.1	Getötete im Straßenverkehr in Deutschland [3][4] .....	1
Abb. 2.1	Grad der experimentellen Kontrolle, des realitätsnahen Fahrens und der verwendeten Technik verschiedener Forschungsparadigmen im Überblick nach [16] .....	4
Abb. 2.2	Szenariextraktion in SHRP2 nach Hankey [26, S. 21].....	6
Abb. 3.1	Überblick zum Aufbau der Arbeit .....	23
Abb. 4.1	Schematischer Aufbau des Datenaufzeichnungssystems in Fahrzeugen der SHRP2 Studie [94] .....	25
Abb. 4.2	Logarithmiertes Odds Ratio nach [74, S. 75] .....	29
Abb. 4.3	Auftrennung des Datensatzes über langsam veränderliche Einflussfaktoren .....	36
Abb. 5.1	Sichtbereiche der Kameras der SHRP2 Studie (links), Beispielframe (rechts oben), Head-Unit (rechts unten) nach [112, S. 32] .....	40
Abb. 5.2	Front-Radarsensor am Kennzeichenhalter (links), Fahrzeugintegrierte Datenaufzeichnungseinheit (rechts) [112].....	40
Abb. 5.3	Aufgezeichnete Daten der SHRP2 Studie nach [112, S. 32].....	41
Abb. 5.4	Aufbau des Vorgehens .....	45
Abb. 5.5	Einteilung maschineller Lernmethoden nach [115, S. 2] .....	46
Abb. 5.6	Beispiel eines Entscheidungsbaums [113, S. 28].....	48
Abb. 5.7	Einteilung eines zweidimensionalen Merkmalsraums in Rechtecke nach [113, S. 30].....	50
Abb. 5.8	Lineare SVM mit separierbaren Daten [128, S. 129].....	53
Abb. 5.9	Schematisches Vorgehen einer 4-fachen Kreuzvalidierung nach [113, S. 23].....	58
Abb. 5.10	Parametrierung des Zeitfensters zur Erzeugung von Merkmalen aus Zeitreihendaten nach [113, S. 42].....	59
Abb. 5.11	Gewichtung der Zeitreihenwerte eines Zeitfensters mit einem Vergessensfaktor nach [113, S. 43].....	61
Abb. 5.12	Gruppierung der langsam veränderlichen Kritikalitätsmaße in Merkmale nach [113, S. 46] .....	62
Abb. 5.13	Überblick zur Funktionsweise von Verfahren zur Merkmalsauswahl nach [134, S. 15].....	64
Abb. 5.14	Schematische Funktionsweise der Wrapper-Methode mit Vorwärtsselektion nach [113, S. 20].....	65
Abb. 5.15	Parameteranalyse für <i>n</i> tree beim Random Forest nach [113, S. 48] .....	66
Abb. 5.16	Parameteranalyse für Gewichtungswert $C$ und Kernelparameter $\sigma$ bei der SVM für Geradeausfahrt nach [113, S. 49].....	67
Abb. 5.17	Konfusionsmatrix einer binären Klassifikation .....	68
Abb. 5.18	ROC-Kurve mit Schwellwert nach [113, S. 26].....	70

Abb. 5.19	Vergleich der Bewertungsgrößen ROC AUC (links) und Treffergenauigkeit (rechts) nach [113, S. 50] .....	71
Abb. 5.20	Einfluss des Zeitbereichs auf die Klassifikationsgüte ROC AUC für Geradeausfahrten (oben) und Kurvenfahrten (unten) nach [113, S. 53].....	74
Abb. 5.21	Einfluss des Zeitfensterendes auf die Wichtigkeit der Merkmale bei Geradeausfahrt (oben) und Kurvenfahrt (unten) nach [113, S. 54-55] .....	76
Abb. 5.22	Einfluss des Fahrerzustands auf die Klassifikationsgüte nach [113, S. 56] .....	78
Abb. 5.23	Kritikalitätsschätzung des Fahrzustandes für Geradeausfahrt (links) und Kurvenfahrt (rechts) von Unfalldatensätzen nach [113, S. 58] .....	79
Abb. 5.24	Verwendete Zeitfensterbereiche zur Erzeugung von Inputpaaren für die kontinuierliche Zeitreihenklassifikation nach [113, S. 59] .....	80
Abb. 5.25	Klassifikationsgüte von Geradeaus- und Kurvenfahrten bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 60] .....	81
Abb. 5.26	Wichtigkeit der Merkmale von Geradeaus- und Kurvenfahrten bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 61] .....	82
Abb. 5.27	Kritikalitätsschätzung des Fahrzustandes von Geradeausfahrten für Unfall- und Baselinedatensätze bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 62].....	83
Abb. 5.28	Kritikalitätsschätzung des Fahrzustandes von Kurvenfahrten für Unfall- und Baselinedatensätze bei der kontinuierlichen Zeitreihenklassifikation nach [113, S. 63] .....	84
Abb. 5.29	Vergleich der Klassifikationsgüte von Support Vector Machine und Random Forest für zeitfensterspezifische Modelle nach [113, S. 66].....	86
Abb. 5.30	Wichtigkeit der Merkmale für Geradeausfahrten bei zeitfensterspezifischen SVM-Modellen nach [113, S. 67].....	87
Abb. 5.31	Wichtigkeit der Merkmale für Kurvenfahrten bei zeitfensterspezifischen SVM-Modellen nach [113, S. 68] .....	88
Abb. 6.1	ROC-Kurve für Geradeausfahrten mit Schwellwerten der Kritikalität für Inputpaare von 0s bis 10s vor einem potentiellen Unfall (oben) und zugehörige Konfusionsmatrizen (unten) nach [113, S. 64].....	93



# Tabellenverzeichnis

Tabelle 2.1	Überblick über Störfallkriterien in verschiedenen Studien (teilweise nach [17, S. 80]).....	7
Tabelle 2.2	Literaturübersicht zur Bestimmung von langsam veränderlichen Einflussfaktoren aus Unfalldatenbanken.....	10
Tabelle 2.3	Quantifizierung von Nebenaufgaben des Fahrers nach [60] .....	11
Tabelle 2.4	Quantifizierung von Fahrerbeeinträchtigung, Fahrerleistung, Fahrfehler und Fahrerablenkung nach [66, S. 2639].....	12
Tabelle 2.5	Vierfeldertafel zur Bestimmung des Assoziationsmaßes Odds Ratio .....	14
Tabelle 2.6	Literaturübersicht zur prädiktiven Schätzung objektiver und subjektiver Kritikalität.....	15
Tabelle 4.1	Überblick aller Eventdaten jedes Datensatzes in SHRP2 [96, S. 11ff.] .....	26
Tabelle 4.2	Auswahl der im Fahrzeug vor dem Unfall vorliegenden Variablen .....	27
Tabelle 4.3	Auswahl der weiter verwendeten Fälle aufgrund der Unfallschwere .....	27
Tabelle 4.4	Festlegung der neutralen Kategorie für jede Variable .....	28
Tabelle 4.5	Vierfeldertafel zur Bestimmung des Assoziationsmaßes Odds Ratio für langsam veränderliche Einflussfaktoren auf die Unfallwahrscheinlichkeit .....	29
Tabelle 4.6	Vierfeldertafel zur Berechnung des Einflusses der Kategorie „Dunkelheit – beleuchtet“ .....	30
Tabelle 4.7	Quantifizierung von langsam veränderlichen Umwelteinflüssen.....	32
Tabelle 4.8	Quantifizierung von langsam veränderlichen Einflüssen aus Fahrerzustand und Fahrmanöver .....	33
Tabelle 5.1	Verwendete Zeitreihendaten aus SHRP2 [95] .....	42
Tabelle 5.2	Exemplarische Eventbewertung mit langsam veränderlichen Kritikalitätsmaßen zur Weiterverwendung im prädiktiven Schätzprozess.....	44
Tabelle 5.3	Bewertender Vergleich von Lernalgorithmen (Auszüge aus [118] und [120]) .....	47
Tabelle 5.4	Kategorien der Eventvariable Pre-Incident Manöver mit mehr Baseline- als Unfalldatensätzen.....	56
Tabelle 5.5	Übersicht zu möglichen Datensatzkombinationen nach [113, S. 41].....	56
Tabelle 5.6	Erzeugung von Merkmalen aus fahrzeugkinematischen Signalen mit standardisierten Methoden nach [113, S. 42].....	59
Tabelle 5.7	Wissensbasierte Erzeugung von Merkmalen aus Radarsensordaten nach [113, S. 42].....	60
Tabelle 5.8	Erzeugung von kombinierten Merkmalen verschiedener Kategorien nach [113, S. 46].....	63
Tabelle 5.9	Vorgehen der Auswertung .....	72
Tabelle 6.1	Transfer der Methode auf andere Anwendungsfälle .....	95

# Literaturverzeichnis

- [1] Statistisches Bundesamt (Destatis), *Verkehrsunfälle - Zeitreihen 2016: (Aktualisierter Stand vom 07.09.2017, Tabelle 10 und 12)*. [Online] Verfügbar: [https://www.destatis.de/DE/Publikationen/Thematisch/TransportVerkehr/Verkehrsunfaelle/VerkehrsunfaelleZeitreihenPDF\\_5462403.pdf?\\_\\_blob=publicationFile](https://www.destatis.de/DE/Publikationen/Thematisch/TransportVerkehr/Verkehrsunfaelle/VerkehrsunfaelleZeitreihenPDF_5462403.pdf?__blob=publicationFile). abgerufen am 04.03.2018.
- [2] World Health Organization 2015, *Summary - Global Status Report on Road Safety 2015*. [Online] Verfügbar: [http://www.who.int/violence\\_injury\\_prevention/road\\_safety\\_status/2015/en/](http://www.who.int/violence_injury_prevention/road_safety_status/2015/en/). abgerufen am 09.05.2017.
- [3] Statistisches Bundesamt (Destatis), *Polizeilich erfasste Unfälle: Unfälle und Verunglückte im Straßenverkehr*. [Online] Verfügbar: <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Verkehrsunfaelle/Tabellen/unfaelle-verunglueckte.html>. abgerufen am 30.04.2019.
- [4] Statistisches Bundesamt (Destatis), *Polizeilich erfasste Unfälle: Straßenverkehrsunfälle, Verunglückte, Anzahl*. [Online] Verfügbar: [https://www.destatis.de/DE/ZahlenFakten/Wirtschaftsbereiche/TransportVerkehr/Verkehrsunfaelle/Tabellen/\\_/Strassenverkehrsunfaelle.html](https://www.destatis.de/DE/ZahlenFakten/Wirtschaftsbereiche/TransportVerkehr/Verkehrsunfaelle/Tabellen/_/Strassenverkehrsunfaelle.html). abgerufen am 04.03.2018.
- [5] Deutscher Verkehrssicherheitsrat, *Vision Zero: Grundlagen & Strategien*. [Online] Verfügbar: [http://www.dvr.de/download2/p3042/3042\\_0.pdf](http://www.dvr.de/download2/p3042/3042_0.pdf). abgerufen am 09.05.2017.
- [6] T. Hummel, M. Kühn, J. Bende, und A. Lang, *Fahrerassistenzsysteme: Ermittlung des Sicherheitspotenzials auf Basis des Schadensgeschehens der deutschen Versicherer*. Berlin: GDV, 2011.
- [7] K. Enke, "Possibilities for improving safety within the driver-vehicle-environment control loop," in *Seventh International Technical Conference on Experimental Safety Vehicles*, Washington, D.C.: Government Printing Office, 1979.
- [8] O. Stengel, A. van Looy, und S. Wallaschkowski, *Digitalzeitalter - Digitalgesellschaft: Das Ende des Industriezeitalters und der Beginn einer neuen Epoche*. Wiesbaden: Springer Fachmedien Wiesbaden, 2017.
- [9] S. K. Zhou, H. Greenspan, und D. Shen, *Deep Learning for Medical Image Analysis*: Elsevier Science, 2017.
- [10] R. Glatz, *Künstliche Intelligenz verschafft Industrie 4.0 weiteren Schub*. [Online] Verfügbar: <https://www.vdma.org/v2viewer/-/v2article/render/16728036>. abgerufen am 28.06.2017.
- [11] H. Schettler, "Im Daten-Dschungel: Wofür Big Data die Marktforschung braucht," *Research & Results*, Bd. 2015, Rn. 4, S. 42, <https://www.research-results.de/fachartikel/2015/ausgabe-4/im-daten-dschungel.html>, 2015.
- [12] P. Gluchowski, "Business Analytics - Grundlagen, Methoden und Einsatzpotenziale," *HMD*, Bd. 53, Rn. 3, S. 273–286, 2016.

- [13] S. Spielberg, *Minority Report (Film)*. USA: Twentieth Century Fox Film Corporation, DreamWorks Pictures, 2002.
- [14] Tesla Deutschland, *Datenschutz u. Rechtsgrundlagen*. [Online] Verfügbar: [https://www.tesla.com/de\\_DE/about/legal?redirect=no](https://www.tesla.com/de_DE/about/legal?redirect=no). abgerufen am 12.11.2017.
- [15] *Road vehicles – Functional safety*, ISO 26262, 2011.
- [16] H. Lietz *et al*, "Methodische und technische Aspekte einer Naturalistic Driving Study," in *Forschungsvereinigung Automobiltechnik e.V. - FAT Schriftenreihe.V*, 2008.
- [17] B. Metz, A. Landau, V. Hargutt, und A. Neukum, "Naturalistic Driving Data - Re-Analyse von Daten aus dem EU-Projekt euroFOT," Würzburger Institut für Verkehrswissenschaften, Berlin, FAT - Schriftenreihe 256, 2013.
- [18] C. Kessler und A. Etemad, "FOT Data: Deliverable D6.8," 2012.
- [19] T. A. Dingus *et al*, "The 100-Car Naturalistic Driving Study - Phase II – Results of the 100-Car Field Experiment," U.S. Department of Transportation, National Highway Traffic Safety Administration DOT HS 810 593, 2006.
- [20] Virginia Tech Transportation Institute VTTI, *SHRP2 NDS Data Access*. [Online] Verfügbar: <https://insight.shrp2nds.us/home>. abgerufen am 07.06.2016.
- [21] M. Benmimoun, F. Fahrenkrog, A. Zlocki, und L. Eckstein, "Incident detection based on vehicle CAN-data within the large scale field operational test "euroFOT"," in *22nd Enhanced Safety of Vehicles Conference (ESV 2011)*, 2011.
- [22] M. Benmimoun, F. Fahrenkrog, A. Zlocki, und L. Eckstein, "Erkennung und Klassifizierung Kritischer Fahrsituationen Mittels Fahrzeugdaten," *ATZ - Automobiltechnische Zeitschrift*, Bd. 114, Rn. 10, S. 820–826, 2012.
- [23] M. A. Brinkmann, D. Kraft, N. M. Bryer, E. Huls, und T. M. Warden, "Driving event data analysis", USA US 13/770,634, Januar 3, 2017
- [24] B. Gahr, B. Ryder, A. Dahlinger, und F. Wortmann, *A Crowd Sensing Approach to Video Classification of Traffic Accident Hotspots*. [Online] Verfügbar: <https://www.researchgate.net/publication/326255691>.
- [25] M. Benmimoun, A. Benmimoun, und J. Küfen, "euroFOT – Optimised data retrieval process for a large scale field test: Manageable by automation?," in *Transport Research Arena Europe*, Brüssel, 2010.
- [26] J. M. Hankey, M. A. Perez, und J. A. McClafferty, "Description of the SHRP 2 Naturalistic Database and the Crash, Near-Crash, and Baseline Data Sets," Report, 2016.
- [27] M. A. Perez *et al*, "Performance of basic kinematic thresholds in the identification of crash and near-crash events within naturalistic driving data," (eng), *Accident; analysis and prevention*, Bd. 103, S. 10–19, 2017.
- [28] A. Ebner, "Referenzszenarien als Grundlage für die Entwicklung und Bewertung von Systemen der Aktiven Sicherheit," Dissertation, Fakultät V - Verkehrs- und Maschinensysteme, Technische Universität Berlin, Berlin, 2014.
- [29] D. M. Wiegand, R. J. Hanowski, und S. E. McDonald, "Commercial motor vehicle health and fatigue study: Final report," The National Surface Transportation Safety Center for Excellence, 2009.
- [30] R. L. Olson, R. J. Hanowski, J. S. Hickman, und J. Bocanegra, "Driver Distraction in Commercial Vehicle Operations," Virginia Tech Transportation Institute, Center for Truck and Bus Safety, Blacksburg, Virginia FMCSA-RRR-09-042, 2010.
- [31] D. V. McGehee, M. Raby, C. Carney, J. D. Lee, und M. L. Reyes, "Extending parental mentoring using an event-triggered video intervention in rural teen drivers," *Journal of Safety Research*, Bd. 38, Rn. 2, S. 215–227, 2007.

- [32] S. Herrmann, W. Utschick, M. Botsch, und F. Keck, "Supervised Learning via Optimal Control Labeling for Criticality Classification in Vehicle Active Safety," in *2015 IEEE 18th International Conference*, S. 2024–2031.
- [33] *Risk management – Guidelines*, ISO 31000:2018, 2018.
- [34] C. Rodemerck, S. Habenicht, A. Weitzel, H. Winner, und T. Schmitt, "Development of a general criticality criterion for the risk estimation of driving situations and its application to a maneuver-based lane change assistance system," in *2012 IEEE Intelligent Vehicles Symposium (IV)*, 2012, S. 264–269.
- [35] Z. Li *et al*, "Surrogate safety measure for evaluating rear-end collision risk related to kinematic waves near freeway recurrent bottlenecks," (eng), *Accident Analysis & Prevention*, Bd. 64, S. 52–61, 2014.
- [36] J. Eggert, "Predictive risk estimation for intelligent ADAS functions," in *2014 IEEE 17th International Conference on Intelligent Transportation Systems (ITSC)*, 2014, S. 711–718.
- [37] J. Ward, G. Agamennoni, S. Worrall, und E. Nebot, "Vehicle collision probability calculation for general traffic scenarios under uncertainty," in *2014 IEEE Intelligent Vehicles Symposium Proceedings: IEEE*, 2014, S. 986–992.
- [38] O. S. Siordia, I. Martin de Diego, C. Conde, G. Reyes, und E. Cabello, "Driving risk classification based on experts evaluation," in *2010 IEEE Intelligent Vehicles Symposium (IV)*, 2010, S. 1098–1103.
- [39] F. Muehlfeld, R. Ertlmeier, J. Happe, und T. Brandmeier, "Criticality estimation of Pre-Crash scenarios," in *2011 14th International IEEE Conference on Intelligent Transportation Systems - (ITSC 2011)*, 2011, S. 1211–1216.
- [40] H. Helai, "Bayesian hierarchical analysis on crash prediction models," Dissertation, Department of Civil Engineering, National University of Singapore, Singapore, 2007.
- [41] R. Yu und M. Abdel-Aty, "Using hierarchical Bayesian binary probit models to analyze crash injury severity on high speed facilities with real-time traffic data," *Accident Analysis & Prevention*, Bd. 62, S. 161–167, 2014.
- [42] L. Ge, T. Hutcherson, Q. Tang, und Q. Gu, "Mixed linear modeling techniques for predicting fatalities in vehicle crashes," in *2017 Systems and Information Engineering Design Symposium (SIEDS): University of Virginia, Charlottesville, Virginia, USA, 28 April 2017*, Piscataway, NJ: IEEE, 2017, S. 353–358.
- [43] M. M. Chong, A. Abraham, und M. Paprzycki, "Traffic Accident Analysis Using Machine Learning Paradigms," *Informatica (slovenia)*, Bd. 29, Rn. 1, S. 89–98, 2005.
- [44] M. Effati, M. A. Rajabi, F. Hakimpour, und S. Shabani, "Prediction of Crash Severity on Two-Lane, Two-Way Roads Based on Fuzzy Classification and Regression Tree Using Geospatial Analysis," *J. Comput. Civ. Eng.*, Bd. 29, Rn. 6, S. 4014099, 2015.
- [45] H. Al Najada und I. Mahgoub, "Big vehicular traffic Data mining: Towards accident and congestion prevention," in *IWCMC 2016: The 12th International Wireless Communications & Mobile Computing Conference: September 5-9, 2016, Paphos, Cyprus*, Piscataway, NJ: IEEE, 2016, S. 256–261.
- [46] S. Krishnaveni und M. Hemalatha, "A Perspective Analysis of Traffic Accident using Data Mining Techniques," *IJCA*, Bd. 23, Rn. 7, S. 40–48, 2011.
- [47] S. Saha, P. Schramm, A. Nolan, und J. Hess, "Adverse weather conditions and fatal motor vehicle crashes in the United States, 1994-2012," (ENG), *Environmental health : a global access science source*, Bd. 15, Rn. 1, S. 104, 2016.
- [48] I. Radun und H. Summala, "Sleep-related Fatal Vehicle Accidents: Characteristics of Decisions Made by Multidisciplinary Investigation Teams," *SLEEP*, Bd. 27, Rn. 2, S. 224–227, 2004.

- [49] L. Fahrmeir, *Statistik: Der Weg zur Datenanalyse*, 2nd Aufl. Berlin [etc.]: Springer, op. 1999.
- [50] S. Das, X. Sun, F. Wang, und C. Leboeuf, "Estimating likelihood of future crashes for crash-prone drivers," *Journal of Traffic and Transportation Engineering (English Edition)*, Bd. 2, Rn. 3, S. 145–157, 2015.
- [51] J.W.H. van Petegem und F. Wegman, "Analyzing road design risk factors for run-off-road crashes in the Netherlands with crash prediction models," *Journal of Safety Research*, Bd. 49, S. 121–127, 2014.
- [52] L.-H. Chen, S. P. Baker, E. R. Braver, und G. Li, "Carrying passengers as a risk factor for crashes fatal to 16-and 17-year-old drivers," *JAMA*, Bd. 283, Rn. 12, S. 1578–1582, 2000.
- [53] T. Unger, "Abkommensunfälle auf Landstraßen 2013: Berichte der ADAC Unfallforschung," ADAC Unfallforschung im ADAC Technik Zentrum Landsberg/Lech, Landsberg/Lech, Okt. 2013.
- [54] Ezio C. Cerrelli, "Fatal Crash Involvements--What are the Odds?," NHTSA National Highway Traffic Safety Administration, Washington, 1997.
- [55] M. Gründl, "Fehler und Fehlverhalten als Ursache von Verkehrsunfällen und Konsequenzen für das Unfallvermeidungspotenzial und die Gestaltung von Fahrerassistenzsystemen," Dissertation, Universität Regensburg, Regensburg, 2005.
- [56] N. Dong, H. Huang, und L. Zheng, "Support vector machine in crash prediction at the level of traffic analysis zones: Assessing the spatial proximity effects," (eng), *Accident; analysis and prevention*, Bd. 82, S. 192–198, 2015.
- [57] H. Holte, "Warum Unfaelle besser durch frühere Verkehrsverstöße als durch vorherige Unfaelle vorausgesagt werden können," *Zeitschrift fuer Verkehrssicherheit*, Bd. 2005/2, Rn. 51, S. 61, 2005.
- [58] R. Yu, M. A. Abdel-Aty, M. M. Ahmed, und X. Wang, "Utilizing Microscopic Traffic and Weather Data to Analyze Real-Time Crash Patterns in the Context of Active Traffic Management," *IEEE Trans. Intell. Transport. Syst.*, Bd. 15, Rn. 1, S. 205–213, 2014.
- [59] C. Oh, J.-S. Oh, und S. G. Ritchie, "Real-Time Hazardous Traffic Condition Warning System: Framework and Evaluation," *IEEE Trans. Intell. Transport. Syst.*, Bd. 6, Rn. 3, S. 265–272, 2005.
- [60] S. G. Klauer, T. A. Dingus, V. L. Neale, J. D. Sudweeks, und D. J. Ramsey, "The impact of driver inattention on near-crash/crash risk: An analysis using the 100-car naturalistic driving study data," Virginia Polytechnic Institute and State University, Blacksburg; National Highway Traffic Safety Administration, 2006.
- [61] L. Malta *et al*, "D6.4 Final results: Impacts on traffic safety," euroFOT consortium, Aachen, 2012. [Online] Verfügbar: [http://www.eurofot-ip.eu/en/library/deliverables/sp6\\_d64\\_final\\_results\\_impacts\\_on\\_traffic\\_safety.htm](http://www.eurofot-ip.eu/en/library/deliverables/sp6_d64_final_results_impacts_on_traffic_safety.htm).
- [62] J. S. Hickman, R. J. Hanowski, und J. Bocanegra, "Distraction in Commercial Trucks and Buses: Assessing Prevalence and Risk in Conjunction with Crashes and Near-Crashes," Virginia Tech Transportation Institute, Center for Truck and Bus Safety FMCSA-RRR-10-049, 2010.
- [63] T. Victor *et al*, *Analysis of Naturalistic Driving Study Data: Safer Glances, Driver Inattention, and Crash Risk*. Washington, D.C.: Transportation Research Board, 2014.
- [64] J. Engström, J. Werneke, J. Bärghman, N. Nguyen, und B. Cook, "Analysis of the role of inattention in road crashes based on naturalistic on-board safety monitoring data," in *PROCEEDINGS of the 3rd International Conference on Driver Distraction and Inattention*, 2013, S. 1–17.

- [65] C. Carney, D. McGehee, K. Harland, M. Weiss, und M. Raby, "Using Naturalistic Driving Data to Examine Teen Driver Behaviors Present in Motor Vehicle Crashes, 2007-2015," University of Iowa, Washington, DC, 2016.
- [66] T. A. Dingus *et al*, "Driver crash risk factors and prevalence evaluation using naturalistic driving data," (eng), *Proceedings of the National Academy of Sciences of the United States of America*, Bd. 113, Rn. 10, S. 2636–2641, 2016.
- [67] M. M. Ahmed, "Driver Performance and Behavior in Adverse Weather Conditions: An Investigation Using the SHRP2 Naturalistic Driving Study Data," Department of Civil and Architectural Engineering, University of Wyoming, Wyoming, USA, 2016.
- [68] P. Jovanis, J. Aguero-Valverde, K.-F. Wu, und V. Shankar, "Analysis of Naturalistic Driving Event Data: Omitted-Variable Bias and Multilevel Modeling Approaches," *Transportation Research Record*, Bd. 2236, S. 49–57, 2011.
- [69] S. Das, B. K. Brimley, T. Lindheimer, und A. Pant, "Safety Impacts of Reduced Visibility in Inclement Weather," Texas A&M Transportation Institute, College Station, Texas, USA ATLAS-2017-19, 2017.
- [70] S. L. Hallmark *et al*, "Analysis of Naturalistic Driving Study Data: Roadway Departures on Rural Two-Lane," FINAL REPORT, Center for Transportation Research and Education, Institute for Transportation, Iowa State University, Iowa, USA SHRP 2 S08D, 2014.
- [71] N. Arbabzadeh und M. Jafari, "A Data-Driven Approach for Driving Safety Risk Prediction Using Driver Behavior and Roadway Information Data," *IEEE Trans. Intell. Transport. Syst.*, S. 1–15, 2017.
- [72] D. Lord und F. Mannering, "The statistical analysis of crash-frequency data: A review and assessment of methodological alternatives," *Transportation Research Part A: Policy and Practice*, Bd. 44, Rn. 5, S. 291–305, 2010.
- [73] M. Egger und O. Razum, *Public Health: Sozial- und Präventivmedizin kompakt*. De Gruyter, 2014.
- [74] S. Lemeshow, D. W. Hosmer Jr, J. Klar, und S. K. Lwanga, *Adequacy of sample size in health studies*. Chichester: John Wiley & Sons Ltd, 1990.
- [75] J. Hedderich und L. Sachs, *Angewandte Statistik: Methodensammlung mit R*, 15th Aufl. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016.
- [76] R. Kluger und B. L. Smith, "Pattern matching longitudinal time series data to identify crashes in naturalistic driving data," in *ITS 21st World Congress 2014*, Detroit, Michigan, USA, 2014, S. 3329–3339.
- [77] R. Kluger, B. L. Smith, H. Park, und D. J. Dailey, "Identification of safety-critical events using kinematic vehicle data and the discrete fourier transform," *Accident Analysis & Prevention*, Bd. 96, S. 162–168, 2016.
- [78] T. Einmüller, "Datenabruf und Analyse von Fahrzeugsignalen zur Erstellung einer Störfalldatenbank," Semesterarbeit, Lehrstuhl für Fahrzeugtechnik, Technische Universität München, 2016.
- [79] J. Wang *et al*, "Driving risk assessment using near-crash database through data mining of tree-based model," (eng), *Accident Analysis & Prevention*, Bd. 84, S. 54–64, 2015.
- [80] F. Damerow und J. Eggert, "Predictive risk maps," in *2014 IEEE 17th International Conference on Intelligent Transportation Systems - (ITSC 2014)*, 2014, S. 703–710.
- [81] C. Xu, A. P. Tarko, W. Wang, und P. Liu, "Predicting crash likelihood and severity on freeways with real-time loop detector data," *Accident Analysis & Prevention*, Bd. 57, S. 30–39, 2013.
- [82] R. Yu und M. Abdel-Aty, "Utilizing support vector machine in real-time crash risk evaluation," *Accident Analysis & Prevention*, Bd. 51, S. 252–259, 2013.

- [83] A. Chaulwar, M. Botsch, und W. Utschick, "A machine learning based biased-sampling approach for planning safe trajectories in complex, dynamic traffic-scenarios," in *28th IEEE Intelligent Vehicles Symposium: June 11-14, 2017, Redondo Beach, California, USA*, Piscataway, NJ: IEEE, 2017, S. 297–303.
- [84] E. J. Lopez Pulgarin, G. Herrmann, und U. Leonards, "Drivers' Manoeuvre Classification for Safe HRI," in *Lecture Notes in Computer Science, Bd. 10454, Towards Autonomous Robotic Systems: 18th Annual Conference, TAROS 2017, Guildford, UK, July 19-21, 2017, Proceedings*, Y. Gao, S. Fallah, Y. Jin, und C. Lekakou, Hrsg, Cham, s.l.: Springer International Publishing, 2017, S. 475–483.
- [85] C. Rodemer, "Potential of Driving Style Adaptation for a Maneuver Prediction System at Urban Intersections," Dissertation, Fachbereich Maschinenbau, Technische Universität Darmstadt, Darmstadt, 2017.
- [86] J. Wallner, T. Tang, und M. Lienkamp, "Development of an Emergency Braking System for Teleoperated Vehicles Based on Lidar Sensor Data," in *Proceedings of the 11th International Conference on Informatics in Control, Automation and Robotics, September 1-3, 2014, in Vienna, Austria*, Setubal: Science and Technology Publications, 2014, S. 569–576.
- [87] C.-F. Lin, A. G. Ulsoy, und D. J. LeBlanc, "Vehicle dynamics and external disturbance estimation for vehicle path prediction," *IEEE Trans. Contr. Syst. Technol*, Bd. 8, Rn. 3, S. 508–518, 2000.
- [88] J. Jordan, C. Ruhhammer, H. Kloeden, und M. Kleinsteuber, "Learning Driving Scene Prediction from Environmental Perception of Vehicle Fleet Data," in *2015 IEEE 18th International Conference on Intelligent Transportation Systems - (ITSC 2015)*, 2015, S. 547–552.
- [89] S. Klingelschmitt und J. Eggert, "Using Context Information and Probabilistic Classification for Making Extended Long-Term Trajectory Predictions," in *2015 IEEE 18th International Conference on Intelligent Transportation Systems - (ITSC 2015)*, 2015, S. 705–711.
- [90] S. Lefèvre, D. Vasquez, und C. Laugier, "A survey on motion prediction and risk assessment for intelligent vehicles," *Robomech J*, Bd. 1, Rn. 1, 2014.
- [91] F. Guo, S. G. Klauer, J. M. Hankey, und T. A. Dingus, "Near Crashes as Crash Surrogate for Naturalistic Driving Studies," *Transportation Research Record Journal of the Transportation Research Board*, Bd. 2147, Rn. -1, S. 66–74, [https://www.researchgate.net/profile/Feng\\_Guo16/publication/275850991\\_Near\\_Crashes\\_as\\_Crash\\_Surrogate\\_for\\_Naturalistic\\_Driving\\_Studies/links/56e0290e08ae9b93f79c25ac.pdf](https://www.researchgate.net/profile/Feng_Guo16/publication/275850991_Near_Crashes_as_Crash_Surrogate_for_Naturalistic_Driving_Studies/links/56e0290e08ae9b93f79c25ac.pdf), 2010.
- [92] J. K. Jonasson und H. Rootzen, "Internal validation of near-crashes in naturalistic driving studies: a continuous and multivariate approach," (eng), *Accident Analysis & Prevention*, Bd. 62, S. 102–109, 2014.
- [93] J. Wallner, S. Engel, und F. Diermeyer, "Determination of Static Criticality Measures for Predictive Safety State Evaluation in Vehicles (Poster published, Paper in Review)," in *Conference on Intelligent Transport Systems in Theory and Practice 2017 (mobil.TUM 2017)*, München, 2017.
- [94] A. Blatt *et al*, *Naturalistic Driving Study: Field data collection*. Washington, DC: Transportation Research Board, 2015.
- [95] C. Witcher *et al*, "Predictive Safety - Analysis, whether statistical data can be used for driving safety purposes," Datensatz, 2016. [Online] Verfügbar: <https://dataverse.vtti.vt.edu/citation?persistentId=doi:10.15787/VTT1/O5TEIX>.

- [96] Virginia Tech Transportation Institute (VTTI), "SHRP2 Researcher Dictionary for Video Reduction Data," Blacksburg, Virginia Version 3.4, 2015.
- [97] J. Feiler, "Entwicklung eines Kritikalitätsmaßes zur Sicherheitsbewertung eines Fahrzustandes," Semesterarbeit, Lehrstuhl für Fahrzeugtechnik, Technische Universität München, 2016.
- [98] U. Mueller, B. Nauck, und A. Diekmann, *Handbuch der Demographie 2: Anwendungen*: Springer Berlin Heidelberg, 2013.
- [99] D. d. Waard, "The Measurement of Drivers' Mental Workload," Dissertation, University of Groningen, Groningen, 1996.
- [100] Statistisches Bundesamt (Destatis), *Verkehrsunfälle - Zeitreihen 2015: (Stand: 12.10.2016)*. [Online] Verfügbar: [https://www.destatis.de/DE/Publikationen/Thematisch/TransportVerkehr/Verkehrsunfaelle/VerkehrsunfaelleZeitreihenPDF\\_5462403.pdf?\\_\\_blob=publicationFile](https://www.destatis.de/DE/Publikationen/Thematisch/TransportVerkehr/Verkehrsunfaelle/VerkehrsunfaelleZeitreihenPDF_5462403.pdf?__blob=publicationFile). abgerufen am 09.05.2017.
- [101] J. Wallner, S. Engel, F. Diermeyer, und M. Lienkamp, "Big Data zur prädiktiven Sicherheitserhöhung in Fahrzeugen," in *7. Tagung Fahrerassistenz*, München, 2015.
- [102] H. Watanabe, L. Tobisch, T. Laudien, J. Wallner, und G. Prokop, "A Method for the Estimation of Coexisting Risk-Inducing Factors in Traffic Scenarios," in *30th IEEE Intelligent Vehicles Symposium 2019*, Paris, 2019.
- [103] H. Watanabe, L. Tobisch, J. Rost, J. Wallner, und G. Prokop, "Scenario Mining for Development of Predictive Safety Functions (accepted)," in *2019 IEEE International Conference on Vehicular Electronics and Safety*, Cairo, 2019.
- [104] B. Ma, "Design und Implementierung einer Datenschnittstelle für einen verbreiteten Verkehrsinformationsdienst," Semesterarbeit, TU München, 2015.
- [105] Y. Donghe, "Data Logging and Analysis of Online Traffic Data for Vehicle Safety Functions," Bachelorarbeit, TU München, 2016.
- [106] C. Miethaner, "Orts- und zeitbasierte Analyse von Online Traffic Daten für Fahrzeugsicherheitsfunktionen," Semesterarbeit, TU München, 2017.
- [107] H. A. Najada und I. Mahgoub, "Autonomous vehicles safe-optimal trajectory selection based on big data analysis and predefined user preferences," in *2016 IEEE 7th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*: IEEE, 2016, S. 1–6.
- [108] Honglei Ren, You Song, Jingwen Wang, yucheng HU, und Jinzhi Lei, "A Deep Learning Approach to the Citywide Traffic Accident Risk Prediction," in *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*
- [109] Z. Spielman *et al*, "Machine Learning and Big Data Analytics in Support of Fleet Safety During Severe Weather," in *AHFE 2017: Advances in Human Aspects of Transportation*, 2017, S. 662–671.
- [110] B. Ryder, B. Gahr, P. Egolf, A. Dahlinger, und F. Wortmann, "Preventing traffic accidents with in-vehicle decision support systems - The impact of accident hotspot warnings on driver behaviour," *Decision Support Systems*, Bd. 99, S. 64–74, 2017.
- [111] J. Wallner, F. Diermeyer, und S. Engel, "Predictive modeling for vehicle time-series data," in *Advanced Vehicle Control: Proceedings of the 13th International Symposium on Advanced Vehicle Control (AVEC'16), September 13-16, 2016, Munich, Germany*, J. Edelmann, M. Plöchl, und P. E. Pfeffer, Hrsg, London: Crc Press, 2016, S. 477–482.
- [112] K. L. Campbell, "The SHRP 2 Naturalistic Driving Study: Addressing Driver Performance and Behavior in Traffic Safety," in *TR News September-October 2012: Blueprints to Improve Highway Safety*, Washington, D.C.: Transportation Research Board, 2012, S. 30–37.



- [113] E. Ye, "Kritikalitätsschätzung von Fahrzeugsignalen mit Maschinenlernverfahren," Semesterarbeit, Lehrstuhl für Fahrzeugtechnik, Technische Universität München, 2017.
- [114] T. Reitmaier, *Aktives Lernen für Klassifikationsprobleme unter der Nutzung von Strukturinformationen*. Kassel: Kassel University Press GmbH, 2015.
- [115] K. P. Murphy, *Machine learning: A probabilistic perspective*. Cambridge, Mass.: MIT Press, 2012.
- [116] T. Hastie, R. Tibshirani, und J. Friedman, *The Elements of Statistical Learning: Data mining, Inference, and Prediction*, 7th Aufl. New York, NY: Springer-Verlag New York, NY, 2008.
- [117] S. B. Kotsiantis, I. D. Zaharakis, und P. E. Pintelas, "Machine learning: A review of classification and combining techniques," (en), *Artif Intell Rev*, Bd. 26, Rn. 3, S. 159–190, <https://link.springer.com/content/pdf/10.1007%2Fs10462-007-9052-3.pdf>, 2007.
- [118] S. B. Kotsiantis, "Supervised Machine Learning: A Review of Classification Techniques," *Informatica*, Bd. 31, Rn. 3, <http://www.informatica.si/index.php/informatica/article/download/148/140>, 2007.
- [119] R. Caruana und A. Niculescu-Mizil, "An empirical comparison of supervised learning algorithms," in *Proceedings of the 23rd international conference on Machine learning*, New York, NY: ACM, 2006, S. 161–168.
- [120] A. Singh, N. Thakur, und A. Sharma, "A Review of Supervised Machine Learning Algorithms," in *INDIACom-2016: Proceedings of the 10th INDIACom; 2016 3rd International Conference on Computing for Sustainable Global Development : (16th-18th March, 2016)*, M. N. Hoda, Hrsg, Piscataway, NJ: IEEE, 2016, S. 1310–1315.
- [121] L. Breiman, J. Friedman, C. J. Stone, und R. A. Olshen, *Classification and regression trees*: Chapman and Hall/CRC, 1984.
- [122] M. Bramer, *Principles of Data Mining*: Springer London, 2016.
- [123] G. Louppe, "Understanding Random Forests: From Theory to Practice," PhD Dissertation, Faculty of Applied Sciences, Department of Electrical Engineering & Computer Science, University of Liège, Lüttich, 2014.
- [124] M. Kuhn und K. Johnson, *Applied predictive modeling*. New York, NY: Springer, 2013.
- [125] L. Breiman, "Random Forests," *Machine Learning*, Bd. 45, Rn. 1, S. 5–32, 2001.
- [126] Y. Freund und R. E. Schapire, "Experiments with a New Boosting Algorithm," in *Machine Learning: Proceedings of the Thirteenth International Conference*, 1996.
- [127] C. Cortes und V. Vapnik, "Support-Vector Networks," *Machine Learning*, Bd. 20, Rn. 3, S. 273–297, 1995.
- [128] C. J.C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," *Data Mining and Knowledge Discovery*, Bd. 2, Rn. 2, S. 121–167, 1998.
- [129] W. Rödter, *Wirtschaftsmathematik für Studium und Praxis 1: Lineare Algebra*. Berlin, Heidelberg: Springer Berlin Heidelberg; Imprint; Springer, 1997.
- [130] P. Pfaffenbichler, F. Unterpertinger, H. Lechner, G. Simader, und M. Bannert, "BikeRisk - Risiken des Radfahrens im Alltag," in *Forschungsarbeiten des oesterreichischen Verkehrssicherheitsfonds*, 2011.
- [131] M.-F. Botsch, *Machine learning techniques for time series classification*, 1st Aufl. Göttingen: Cuvillier, 2009.
- [132] H. Winner, S. Hakuli, F. Lotz, und C. Singer, *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*, 3rd Aufl. Wiesbaden: Springer Vieweg, 2015.

- [133] I. Guyon und A. Elisseeff, “An Introduction to Variable and Feature Selection,” *Journal of Machine Learning Research*, Bd. 3, Rn. Mar, S. 1157–1182, <http://www.jmlr.org/papers/volume3/guyon03a/guyon03a.pdf>, 2003.
- [134] I. Guyon, “Feature Selection Methods from Correlation to Causality,” in *NIPS 2008 Workshop on Kernel Learning*, 2008.
- [135] N. Sánchez-Marotoño, A. Alonso-Betanzos, und M. Tombilla-Sanromán, “Filter Methods for Feature Selection – A Comparative Study,” in *Lecture Notes in Computer Science*, Vol. 4881, *Intelligent data engineering and automated learning: 8th international conference ; proceedings*, H. Yin, Hrsg, Berlin, Heidelberg, New York, NY: Springer, 2007, S. 178–187.
- [136] MathWorks, *Dokumentation zum Paket fitcensemble von Ensemble Learning Methoden für Klassifikationsaufgaben: MATLAB Version R2017a*. [Online] Verfügbar: <https://de.mathworks.com/help/stats/fitcensemble.html>. abgerufen am 07.05.2019.
- [137] MathWorks, *Dokumentation zur Funktion bayesopt zur Optimierung von Machine Learning Hyperparameter: MATLAB Version R2017a*. [Online] Verfügbar: <https://de.mathworks.com/help/stats/bayesopt.html>. abgerufen am 17.05.2019.
- [138] MathWorks, *Dokumentation zur Erstellung von Support Vector Machine (SVM) Klassifikationsmodellen mit der Funktion fitcsvm: MATLAB Version R2017a*. [Online] Verfügbar: <https://de.mathworks.com/help/stats/fitcsvm.html>. abgerufen am 17.05.2019.
- [139] T. A. Runkler, *Data Mining*. Wiesbaden: Vieweg+Teubner, 2010.
- [140] B. Heissing, M. Ersoy, und S. Gies, *Fahrwerkhandbuch: Grundlagen, Fahrdynamik, Komponenten, Systeme, Mechatronik, Perspektiven*, 4th Aufl. Wiesbaden: Springer Vieweg, 2013.
- [141] I. Goodfellow, Y. Bengio, und A. Courville, *Deep Learning*. MIT Press, 2016.
- [142] E. Wahlstrom, O. Masoud, und N. Papanikolopoulos, “Vision-based methods for driver monitoring,” in *The proceedings of the 2003 IEEE International Conference on Intelligent Transportation Systems: October 12-15, 2003, Shanghai Worldfield Convention Hotel, Shanghai, China*, Piscataway, N.J.: IEEE, 2003, S. 903–908.
- [143] M.-H. Sigari, M. Fathy, und M. Soryani, “A Driver Face Monitoring System for Fatigue and Distraction Detection,” *International Journal of Vehicular Technology*, Bd. 2013, 2013.

# Vorveröffentlichungsliste

Während der Anfertigung dieser Dissertation entstanden Veröffentlichungen, Software und Studienarbeiten, in denen Teilaspekte dieser Arbeit vorgestellt wurden.

## **Zeitschriften; Scopus/ Web of Science gelistet (peer-reviewed)**

-

## **Konferenzen, Magazine, etc.; Scopus/ Web of Science gelistet (peer-reviewed)**

- [86] J. Wallner, T. Tang, und M. Lienkamp, "Development of an Emergency Braking System for Teleoperated Vehicles Based on Lidar Sensor Data," in Proceedings of the 11th International Conference on Informatics in Control, Automation and Robotics, September 1-3, 2014, in Vienna, Austria, Setubal: Science and Technology Publications, 2014, S. 569–576.
- [102] H. Watanabe, L. Tobisch, T. Laudien, J. Wallner, und G. Prokop, "A Method for the Estimation of Coexisting Risk-Inducing Factors in Traffic Scenarios (accepted / in press)," in 30th IEEE Intelligent Vehicles Symposium 2019, Paris, 2019.
- [111] J. Wallner, F. Diermeyer, und S. Engel, "Predictive modeling for vehicle time-series data," in Advanced Vehicle Control: Proceedings of the 13th International Symposium on Advanced Vehicle Control (AVEC'16), September 13-16, 2016, Munich, Germany, J. Edlmann, M. Plöchl, und P. E. Pfeffer, Hrsg, London: Crc Press, 2016, S. 477–482.

## **Patente**

-

## **Zeitschriften, Konferenzen, Magazine, Berichte, Konferenzvorträge und -poster, etc.; nicht Scopus/ Web of Science gelistet**

- [93] J. Wallner, S. Engel, und F. Diermeyer, "Determination of Static Criticality Measures for Predictive Safety State Evaluation in Vehicles (Poster published, Paper in Review)," in Conference on Intelligent Transport Systems in Theory and Practice 2017 (mobil.TUM 2017), München, 2017.
- [101] J. Wallner, S. Engel, F. Diermeyer, und M. Lienkamp, "Big Data zur prädiktiven Sicherheitserhöhung in Fahrzeugen," in 7. Tagung Fahrerassistenz, München, 2015.

- [103] H. Watanabe, L. Tobisch, J. Rost, J. Wallner, und G. Prokop, "Scenario Mining for Development of Predictive Safety Functions (accepted)," in 2019 IEEE International Conference on Vehicular Electronics and Safety, Cairo, 2019.

### **Nicht-dissertationsrelevante Veröffentlichungen; Scopus/ Web of Science gelistet (peer-reviewed)**

-

### **Dissertationsrelevante Open-Source Software**

-

# Anhang

## A 5.3.2 Ausgeschlossene fehlerhafte Datensätze aus Kurvenfahrten

Ein Teil der Unfälle der Datensätze aus Kurvenfahrten wurde nicht ausreichend durch das verwendete Sensorset aufgezeichnet beziehungsweise die Unfallschwere falsch bezeichnet. Zum einen liegen Fälle vor, die trotz Frontkollision in der Kurve kein Radarobjekt enthielten. Zum anderen wurden viele Bordsteinrempler oder Fälle mit leichtem, kurzfristigem Abkommen von der Fahrbahn nicht in die geringste und damit eigentlich bereits aussortierte Unfallschwere-Kategorie eingeordnet. Diese Fälle werden daher manuell per Videoanalyse identifiziert und aus der Datensatzkombination „Kurvenfahrt“ ausgeschlossen.

Es bleiben somit noch ca. 75 Unfälle sowie 3.000 Baseline-Fälle übrig. Folgende Liste enthält alle Datensätze aus Kurvenfahrten, die ausgeschlossen wurden, um das Klassifikationsergebnis nicht zu verfälschen.

Tabelle A 5.3.2 Ausgeschlossene Datensätze aus Kurvenfahrten

Ausschlussgrund	Datensatz-IDs
Bordstein-„Kollisionen“	24521266, 24521313, 24522683, 29712540, 29714720, 29714726, 29730846, 29750780, 29859135, 29877322, 29878409, 29880024, 30883533, 31281074, 33574922, 33575087, 35257237, 35258182, 35258329, 36812431, 36841173, 36842974, 60632608, 60632617, 60632630, 60632647, 60632648, 60632653, 60633145, 60633154, 60633158, 61033673, 61109416, 61111553, 61114307, 61114315, 61114485, 61114489, 61114495, 61114496, 61114498, 61211782, 61211783, 61211787, 61211788, 61211789, 61211795, 61211840, 61211844, 61211846, 61211849, 61211853, 61211857, 61211858, 61211925, 61216643, 61385321, 61385880, 61385888, 61385889, 61385900, 61385901, 61385921, 61426764, 61426783, 61426945, 61426975, 64553436, 64574227, 76264669, 76264682, 116591914, 116592038, 128888402, 128888507, 128903604, 128906316, 128906460, 130441803, 131648740, 131785444, 131785449, 131795646, 132522433, 132522483, 132706244, 132804336, 133190068, 133321844, 133753361, 135124481, 135427633, 138116213, 138337962, 138352121, 138353067, 138630073, 142007552, 142007641, 142007836, 142007925, 142049715, 143062663, 143062726, 143391014, 151084871, 151084950, 151351630
Abkommen auf Bankett	31280799 , 36842973, 60633152, 61216945, 61432399, 128888433, 128888500, 128906318, 128906355, 128906467, 130475661, 131795645, 131821508, 131846363, 132520586 , 132520721, 133190050, 133754824, 134934752, 134947920, 135123297, 135191442, 135427642, 135947134, 136343991, 138313794, 138361495, 138364385, 138592592, 138605536, 142005188, 142053515, 142053577, 142121000, 142190414, 142255417, 143288737, 143391093, 150717069, 150717201, 150882989, 151093296, 151093420
Frontkollision ohne Radarobjekt	24522417, 29714730, 29714762, 33574928, 33994000, 35258197, 36304068, 36842972, 36842975, 51722161, 61114314, 61114481, 61211791, 61216653, 61385895, 61426976, 64574238, 76264667, 116162983, 116163025, 116594164, 128888412, 130421940, 132797064, 135191462, 135422975, 136043612, 138352121
Fehlerhafte Fälle	5591654, 7427092, 10528252 61211850, 61211938, 142007468
Sonstiges	6511355, 7878642, 24117800, 24516455, 24517679, 24519529, 29712183, 29714712, 29714766, 29877320, 30879241, 33575044, 33994000, 60632645, 61033668, 76264689, 76264697, 132520573, 132520928, 135366685, 151311041

## A 5.3.4 Ergebnisse der Merkmalsvorauswahl mit der Wrapper Vorwärtsselektion für die SVM

Tabelle A 5.3.4 Ergebnisse der Merkmalsvorauswahl mit der Wrapper Vorwärtsselektion für die SVM

Merkmalsvorauswahl SVM für Geradeausfahrt	Merkmalsvorauswahl SVM für Kurvenfahrten
1. OR_my	1. OR_Verkehrskompl
2. OR_Verkehrskompl	2. OR_prädizierbar
3. std(inv(mindist))	3. inv(mindist)
4. num_obj_front	4. mean(inv(mindist))
5. num_obj_frontseite	5. std(inv(mindist))
6. num_obj_seite	6. max(inv(mindist))
7. exist_Vorderfahrzeug	7. num_obj_front
8. inv(TTC_Vorderfahrzeug)	8. num_obj_paral
9. inv(THW_Vorderfahrzeug)	9. num_obj_antiparal
10. mean(inv(THW_Vorderfahrzeug))	10. num_obj_stat
11. std(a_abs_Vorderfahrzeug)	11. num_obj_gleicherFS
12. min(aTTC_Vorderfahrzeug)	12. max(inv(min(TTC_obj_Dir)))
13. mean(aTTC_Vorderfahrzeug)	13. inv(min(TTC_ObjDir))
14. mean(dist_rel_res_Vorderfahrzeug)	14. inv(TTC_Vorderfahrzeug)
15. std(abs(R))	15. std(inv(TTC_Vorderfahrzeug))
16. mean(a_z)	16. inv(THW_Vorderfahrzeug)
17. std(a_z)	17. mean(inv(THW_Vorderfahrzeug))
18. max(abs(a_z))	18. std(inv(THW_Vorderfahrzeug))
19. min(abs(a_z))	19. a_abs_Vorderfahrzeug
20. mad(abs(a_z))	20. mean(a_abs_Vorderfahrzeug)
21. iqr(abs(a_z))	21. min(aTTC_Vorderfahrzeug)
22. std(Gierrate)	22. mean(aTTC_Vorderfahrzeug)
23. mean(v)	23. min(dist_rel_res_Vorderfahrzeug)
24. max(v)	24. mean(dist_rel_res_Vorderfahrzeug)
25. min(v)	25. TTC_Verkehrskompl_OR
26. mean(v)_OR_my	26. mean(a_x)
27. mean(a_x)_OR_my	27. std(a_x)
28. std(a_y)_my_OR	28. max(a_x)
29. fft(a_y) von 0-1 Hz	29. min(a_x)
30. fft(a_y) von 3-5 Hz	30. mad(abs(a_y))
31. fft(a_z) von 0-1 Hz	31. mean(a_z)
32. fft(a_z) von 3-5 Hz	32. min(abs(a_z))
33. fft(Gierrate) von 0-1 Hz	33. min(abs(Gierrate))
34. fft(Gierrate) von 1-3 Hz	34. mean(v)
35. fft(Gierrate) von 3-5 Hz	35. max(v)
36. fft(v) von 0-0,3 Hz	36. min(v)
37. fft(v) von 0,3-1 Hz	37. mad(v)
38. fft(v) von 0-1 Hz	38. mean(v)_OR_my
39. fft(v) von 1-3 Hz	39. mean(a_x)_my_OR
40. fft(v) von 3-5 Hz	40. std(a_x)_my_OR
	41. mean(abs(a_y))_my_OR
	42. std(a_y)_my_OR
	43. fft(a_x) von 3-5 Hz
	44. fft(a_z) von 1-3 Hz
	45. fft(a_z) von 3-5 Hz

## A 5.3.5 Aufrufe zur Erstellung der von Klassifikationsmodellen

### Random Forest

Der folgende Aufruf dient zur Erstellung von Random Forest Modellen und ist dem Paket fitcensemble von Ensemble Learning Methoden für Klassifikationsaufgaben des Softwarepakets MATLAB R2017a entnommen [136]. Übergeben werden die Merkmale (predictors) und die zugehörige Zielklasse (response). Das Ergebnis des Aufrufs sind zehn Random Forest Modelle (MATLAB: CompactClassificationEnsemble) mit jeweils 150 Entscheidungsbäumen (MATLAB: CompactClassificationTree).

```
classificationRF = fitcensemble(...
    predictors, ...
    response, ...
    'Method', 'Bag', ...
    'FResample', 1, ...
    'Replace', 'on', ...
    'NumLearningCycles', 150, ...
    'Cost', [0 1; 1 0], ...
    'Prior', 'empirical', ...
    'Learners', templateTree('MinLeafSize', 1, 'MinParentSize', 2, 'Prune',
'off', 'Surrogate', 25, 'Cost', [0 1; 1 0]), ...
    'CrossVal', CrossVal_state, ...
    'ClassNames', [1; 2]);
```

### Support Vector Machine

Der Aufruf fitcsvm dient zur Erstellung von SVM-Klassifikationsmodellen mit Hilfe des des Softwarepakets MATLAB R2017a [138]. Übergeben werden die Merkmale (predictors) und die zugehörige Zielklasse (response). Das Ergebnis des Aufrufs sind zehn SVM-Klassifikationsmodelle (MATLAB: CompactClassificationSVM).

```
classificationSVM = fitcsvm(...
    predictors, ...
    response, ...
    'KernelFunction', 'gaussian', ...
    'PolynomialOrder', [], ...
    'CrossVal', CrossVal_state, ...
    'KernelScale', KernelScale, ...
    'Cost', [0 1; 1 0], ...
    'Prior', 'empirical', ...
    'BoxConstraint', BoxConstraint, ...
    'Standardize', true, ...
    'ClassNames', [1; 2]);
```