

Ein Beitrag zur Identifikation der Fahrzeugdynamik basierend auf naturalistischen Fahrdaten

Von der Fakultät für Ingenieurwissenschaften, Abteilung Maschinenbau und Verfahrenstechnik
der
Universität Duisburg-Essen
zur Erlangung des akademischen Grades
eines

Doktors der Ingenieurwissenschaften
Dr.-Ing.

genehmigte Dissertation

von
Sebastian Reicherts
aus
Duisburg

Gutachter: Univ.-Prof. Dr.-Ing. Dr. h.c. Dieter Schramm
Univ.-Prof. Dr.-Ing. Lars Mikelsons
Univ.-Prof. Dr.-Ing. Holger Hirsch

Tag der mündlichen Prüfung: 07.03.2022

Zusammenfassung

Die Entwicklung neuer Funktionen/Services moderner Pkw basiert zu einem großen Teil auf sogenannten Fahrdaten und den darin enthaltenen Informationen. Fahrdaten, die während des Betriebs des Fahrzeugs gewonnen werden, können ebenfalls zur Fahrzeugoptimierung genutzt werden. Gerade durch die zuletzt stark gestiegene verfügbare Datenmenge stellt die Analyse der vorhandenen Daten, also die Informationsgewinnung, hierbei eine ebenso große Herausforderung dar wie die reine Messung, Datenaufzeichnung und -speicherung. Seit Beginn der 2000er-Jahre werden verstärkt naturalistische Fahrdaten, also Daten, die während alltäglicher Fahrten im öffentlichen Straßenverkehr aufgezeichnet werden, unter anderem in der Unfall- und Fahrverhaltensforschung eingesetzt. Eine alternative und bisher wenig erforschte Anwendung ist der Einsatz von naturalistischen Fahrdaten für Fahrdynamikuntersuchungen (bspw. die Identifikation von Fahrdynamikmodellen). Einzelne Untersuchungen zeigen bereits die Potentiale naturalistischer Fahrdaten für diesen Anwendungsbereich. Hierbei wird allerdings bisher weder die erreichbare Modellgüte noch der Informationsgehalt, der über ungeplantes Fahren in Bezug auf die Fahrdynamik erfasst werden kann, untersucht.

An dieser Stelle setzt die vorliegende Arbeit an. Erst die Analyse des Informationsinhaltes der Fahrdaten erlaubt auch eine Abschätzung der notwendigen Studiendauer für eine spezifische Fragestellung sowie eine Aussage, ob in Alltagsfahrten aufgezeichnete Daten sich zur Beantwortung dieser eignen. Um diese bisher nicht erforschten Aspekte zu untersuchen, werden die Daten einer einjährigen Naturalistic Driving Study (NDS) analysiert und eine Methode präsentiert, wie aus naturalistischen Fahrdaten Erkenntnisse zur Fahrdynamik gewonnen werden können.

Zur Bewertung der aufgezeichneten Datenbasis wird basierend auf den physikalischen Grenzen eines Pkws, den zu erwartenden Betriebsbedingungen sowie statistischen Größen gezeigt, wie der Informationszugewinn über die Dauer einer solchen Studie abnimmt. Die Diskussion über die Wahrscheinlichkeit, mit zusätzlichen Fahrten weitere Informationen zu gewinnen, stellt einen entscheidenden Punkt für den Einsatz von NDS zur Fahrdynamikidentifikation dar und spielt auch für die Definition eines Studienendes eine wichtige Rolle.

Anhand von verschiedenen Modellen wird zudem gezeigt, dass die in den Daten einer NDS enthaltenen Informationen ausreichen, um für große Teile der Fahrzeugdynamik gültige Modelle zu generieren. Dazu wird die Querdynamik eines Pkws auf Basis theoretischer und experimenteller Modelle untersucht und anhand einer zuvor validierten Referenz bewertbar gemacht.

Abstract

The development of new functions or services in modern passenger vehicles is to a great extent relying on driving data and the information contained within. In addition, the driving data, which are captured during the use of the vehicle, can be used for optimization of the vehicles. The increase in volume of available data means its analysis has become as great a challenge as the measurement or data storage. Since the beginning of the century so called naturalistic driving data, this refers to data taken during everyday drives and on public roads, has been used for research on accidents or the driver's behavior. An alternative use case for these naturalistic data is the analysis of vehicle dynamics (e. g. the identification of vehicle dynamics models). Single studies using naturalistic driving data have already shown the potential for this area of research. So far, their scope has been limited and neither the information gained from everyday drives nor the resulting model quality has been analyzed.

This thesis contributes to these points of interest. The analysis of information contained in driving data and with respect to a specific research question, makes a statement regarding the necessary study duration as well as a judgement on whether naturalistic driving data is sufficient to solve the underlying task. Data taken in a Naturalistic Driving Study (NDS) over a year is analyzed to approach these topics. A method is presented showing how to best use naturalistic driving data to gain knowledge on vehicle dynamics.

An evaluation of the captured data especially regarding the information content is based on physical boundaries of the vehicle, the expected operation conditions as well as statistical quantities. This thesis demonstrates how the gain of information decreases as the data basis builds with increasing study duration. The likeliness to gain more information through continuing a study is one important factor when discussing the potential of using NDS in the area of vehicle dynamics and it also serves as one termination criterion for the measurement phase.

Besides capturing any information possible with a given set-up (an NDS) it is most important to understand whether the information is sufficient to solve the given task. This thesis uses the lateral vehicle dynamics as an example and analyses the validity of the models and rates their accuracy against a highly precise and valid reference model. By using two different vehicle dynamics models that are identified based on the NDS data it is shown that valid dynamics models can be created with the proposed method for a large vehicle dynamics range.

Inhaltsverzeichnis

Abkürzungen und Formelzeichen	ix
1 Einleitung	1
1.1 Datennutzung in der Automobiltechnik	1
1.2 Gliederung der Arbeit	5
2 Grundlagen	7
2.1 Grundlagen der Systemanalyse und Identifikation	7
2.1.1 Systemanalyse	7
2.1.2 Parameteridentifikation	11
2.2 Identifikation in der Fahrzeugdynamik	16
2.2.1 Dynamik eines Personenkraftfahrzeugs	16
2.2.2 Anwendungsfelder von Fahrdynamikmodellen	17
2.2.3 Fahrdynamikmodelle	18
2.2.4 Fahrversuch	20
2.3 Naturalistic Driving Study	22
2.3.1 Begriffserklärung Naturalistic Driving Study	22
2.3.2 Forschungsschwerpunkte von Naturalistic Driving Studies	24
2.3.3 Beispiele für Naturalistic Driving Studies	25
2.4 Grundlagen zu Messgrößenerfassung und Buskommunikation	27
2.4.1 Messtechnikgrundlagen	27
2.4.2 Bussysteme im Fahrzeug	29
2.4.3 Buszugriff	30
2.4.4 CAN-Kommunikation	31
2.5 Grundlagen der Statistik	33
2.5.1 Statistische Begriffe	33
2.5.2 Statistische Analysemethoden	34

2.6	Relevante Forschungsarbeiten	39
2.6.1	Identifikation der Fahrdynamik am Fahrversuch	39
2.6.2	Identifikation der Fahrdynamik mit naturalistisch-nahen Fahrdaten	41
2.7	Bisheriger Stand der Forschung	42
2.8	Wissenschaftlicher Beitrag	43
3	Naturalistic Driving Studies in der Fahrdynamik	45
3.1	Identifikationsprozess für eine Naturalistic Driving Study	45
3.1.1	Identifikationsprozess für die Anforderungen einer NDS	45
3.1.2	Adäquanz der Studiendaten	48
3.2	Aufbau und Definition der Fahrstudie	50
3.3	Messgrößen und Datenverarbeitung der Fahrstudie	52
3.3.1	Datenzugriff und Datenspeicherung	52
3.3.2	Messgrößenauswahl und Definition der Abtastraten	53
3.4	Verarbeitungsschritte der Studiendaten	54
3.5	Limitierung des Querbeschleunigungsmesswerts	56
3.5.1	Rotationseinflüsse auf den Querbeschleunigungsmesswert	58
3.5.2	Messfehler durch einen Wankwinkel	59
3.5.3	Auswirkungen des Messfehlers auf die Identifikation	61
4	Daten der Fahrstudie	63
4.1	Nutzungsverhalten des Versuchsträgers	63
4.1.1	Beschreibung der Studiendaten	64
4.1.2	Vergleichsstudien zur Einordnung der Studiendaten	67
4.2	Fahrdynamische Messgrößen im Alltag	72
4.2.1	Längsgeschwindigkeit des Versuchsträgers	72
4.2.2	Kombinierte Fahrzeugbeschleunigungen	74
4.2.3	Lenkradwinkel und Lenkradwinkelgeschwindigkeit	80
4.3	Statistische Analyse des Datensatzes auf Adäquanz	81
4.3.1	Ablauf der statistischen Analyse	82
4.3.2	Auswertung der Kullback-Leibler-Divergenz	84
4.4	Teilung Studiendaten in Subdatensätze gleicher Fahrdauer	87
5	Modellbildung der Querdynamik	91
5.1	Systemgrenzen des Modells	91
5.2	Datenbalancierung durch Segmentierung der Fahrten	92
5.2.1	Segmentierung einer Fahrt in Fahrereignisse	93
5.2.2	Segmentierte Studiendaten	94
5.3	Theoretische Modellbildung mit einem Linearen Einspurmodell	98
5.3.1	Mathematische Beschreibung	98
5.3.2	Eignung des Modells für die Studiendaten	102
5.3.3	Parameteridentifikation	103
5.3.4	Eigenlenkgradienten der Subdatensätze	104

5.4	Experimentelle Modellbildung mit einem Künstlichen Neuronalen Netz . . .	106
5.4.1	Auswahl der Netzarchitektur	107
5.4.2	Datenauswahl für das Modelltraining	109
5.4.3	Identifikation bzw. Modelltraining	109
5.4.4	Auswertung des Modelltrainings	110
6	Validierung	113
6.1	Validierungsanforderung	113
6.2	Validierung an naturalistischen Fahrten	116
6.2.1	Fahrdaten des Validierungsmonats	116
6.2.2	Fehlermetrik	117
6.2.3	Statistische Fehleranalyse	121
6.2.4	Auswertung eines Abschnittes einer Fahrt	125
6.3	Validierung an Referenzsimulation: Stationäre Kreisfahrt	130
6.4	Validierung der KNN mit balancierter Datenbasis	135
6.4.1	Validierungsmonat: Fehlermetrik	135
6.4.2	Validierung an Referenzsimulation: Stationäre Kreisfahrt	136
6.5	Validierung seltener Fahrereignisse	138
6.5.1	Validierung hoher Querbeschleunigungen	138
6.5.2	Validierung transienten Verhaltens	140
6.6	Erkenntnisse der Modellvalidierung	145
7	Zusammenfassung und weiterführende Aspekte	149
7.1	Zusammenfassung und Beitrag dieser Arbeit	149
7.2	Anknüpfungspunkte zukünftiger Arbeiten	150
A	Weiterführende Betrachtungen und Ergänzungen	153
A.1	Messgrößenerfassung	153
A.1.1	Loggerkomponenten	153
A.1.2	CAN-Messgrößen	153
A.2	Installation einer GPS-Antenne in den Versuchsträger	154
A.3	Signalverarbeitung	155
A.3.1	Kommunikation mit dem Fahrzeug-Gateway	155
A.3.2	Signalrekonstruktion	156
A.3.3	Signalaufbereitung	158
A.4	Ergänzungen zur Kullback-Leibler-Divergenz	159
A.4.1	Anwendbarkeit der Rule of Thumb	159
A.4.2	Kullback-Leibler-Divergenz für große Datenpakete	161
A.5	Lineares Einspurmodell: Parametergrenzen der Identifikation	163
A.6	Ford C-Max 2013: Technische Spezifikation	165
A.7	Ethische Aspekte einer Probandenstudie	168
	Abbildungsverzeichnis	169

Tabellenverzeichnis	171
Literatur	173

Abkürzungen und Formelzeichen

Abkürzungen

Abkürzung	Bedeutung
A/D	Analog/Digital
BEV	engl.: <i>Battery Electric Vehicle</i> (batterieelektrisches Fahrzeug)
bKNN	balanciertes Künstliches Neuronales Netz
CAN	engl.: <i>Controller Area Network</i>
CoG	engl.: <i>Center of Gravity</i> (Schwerpunkt)
DLC	engl.: <i>Data Link Connector</i> (Diagnoseschnittstelle)
ECU	engl.: <i>Electronic Control Unit</i> (Steuergerät)
ESM	Einspurmodell
FD	Fahrdauer
FOT	engl.: <i>Field Operational Test</i> (Operativer Feldversuch)
FS	Fahrstrecke
GF	Geradeausfahrt
KDE	engl.: <i>Kernel Density Estimator</i> (Kerndichtenschätzer)
KE	Kurvenereignis
KLD	Kullback-Leibler-Divergenz
KNN	Künstliches Neuronales Netz
LSTM	engl.: <i>Long Short-Term Memory</i>
MiD	Mobilität in Deutschland
NDS	engl.: <i>Naturalistic Driving Study</i> (Naturalistische Fahrstudie)
OBD	engl.: <i>On Board Diagnostics</i>
PID	engl.: <i>Parameter Identifier</i>
REEV	engl.: <i>Range Extended Electric Vehicle</i> (batterieelektrisches Fahrzeug mit Reichweitenverlängerer)
RMSE	engl.: <i>Root Mean Squared Error</i> (Quadratwurzel der mittleren Fehlerquadratsumme)
ROT	engl.: <i>Rule of Thumb</i> (Faustregel)

Abkürzungen und Formelzeichen

S5/S20/S70/S140	Subdatensätze aus 5/20/70/140 Std. Fahrdaten
SID	engl.: <i>Service Identifier</i>
UDS	engl.: <i>Unified Diagnostic Services</i>

Formelzeichen

Notationen

Notation	Bedeutung
$ \chi $	Betrag von χ
$\tilde{\chi}$	Median
$\bar{\chi}$	Mittelwert
$\{\chi\}_{i=1}^n$	Menge aus Elementen χ
$f(\chi)$	Funktion f von χ (häufig Verteilungsdichtefunktion)
$h(\chi)$	relative Häufigkeit h von χ
$H(\chi)$	absolute Häufigkeit H von χ
a, b, c	Skalare
$\mathbf{a}, \mathbf{b}, \mathbf{c}$	Vektoren (Zeilenformat)
$\mathbf{A}, \mathbf{B}, \mathbf{C}$	Matrizen

Häufig verwendete Indizes

Index	Bedeutung
$(\cdot)_{E,k,O,D,M}$	Indexschreibweise: E = Erweiterung, k = Zeitschritt, O = Objekt, D = Datenzugehörigkeit/Zeitraum, M = Merkmal/-e
Bsp.: $v_{x,V,Studie,max}$	maximale Fahrzeuglängsgeschwindigkeit des Versuchsträgers im Zeitraum der Studie
$a_{y,1,ESM,S5}$	erster Signalwert der Querbesehleunigung des Einspurmodells basierend auf dem Datensatz S5
$(\cdot)_{l/r}$	links/rechts
$(\cdot)_{v/h}$	Vorder-/Hinterachse
$(\cdot)_{x/y/z}$	Raumrichtungen x, y, z
$(\cdot)_{uni}$	univariate Größe/Verteilung
$(\cdot)_{bi}$	bivariate Größe/Verteilung
$(\cdot)_{ref}$	Referenz
$(\cdot)_{sen}$	gemessener Ausgabewert des Sensors
$(\cdot)_{sim}$	Ausgabe des Simulationsmodells
$(\cdot)_{bKNN}$	Signal/Größe des balancierten Künstlichen Neuronalen Netzes
$(\cdot)_{ESM}$	Signal/Größe des Einspurmodells
$(\cdot)_{KNN}$	Signal/Größe des Künstlichen Neuronalen Netzes
$(\cdot)_V$	bezogen auf den Versuchsträger
$(\cdot)_{euroFOT}$	Fahrdaten der Studie euroFOT
$(\cdot)_{PREMIUM}$	Fahrdaten der Studie PREMIUM

$(\cdot)_{\text{PREMIUM BEV}}$	Fahrdaten batterieelektrischer Fahrzeuge aus PREMIUM
$(\cdot)_{\text{PREMIUM REEV}}$	Fahrdaten batterieelektrischer Fahrzeuge mit Reichweitenverlängerer aus PREMIUM
$(\cdot)_{\text{S5/S20/S70/S140}}$	basierend auf dem Subdatensatz S5/S20/S70/S140
$(\cdot)_{\text{Studie}}$	Zeitraum der Studie
$(\cdot)_{\text{VM}}$	Zeitraum des Validierungsmonats
$(\cdot)_{\text{min/max}}$	minimaler/maximaler Wert
$(\cdot)_{\text{FD/FS}}$	Fahrdauer/-strecke

Verwendete Symbole

Lateinische Buchstaben:

Symbol	Einheit	Bedeutung
$C_{P/Q}$		Faktor zur Aufwärts-/Abwärtsabtastung
D_{KL}		Funktions-/Divergenzwert der Kullback-Leibler-Divergenz
EG	rad s ² /m	Eigenlenkgradient
F	N	allgemeine Kraft
$F_{v/h,x/y}$	N	Reifenkraft (vorne/hinten, längs/quer)
F_W	N	externe Kraft, die durch aerodynamische Effekte entsteht
\mathbf{H}		Bandbreiten-Matrix
J_z	kg m ²	Trägheitsmoment um z
K		Kern eines Kerndichteschätzers
M	Nm	allgemeines Moment
M_W	Nm	Moment, das durch aerodynamische Effekte entsteht
O_E		Ursprung des globalen (engl.: <i>earth</i>) Koordinatensystems
O_V		Ursprung des ortsfesten Koordinatensystems im Versuchsträger
P		Zeitspanne/-raum
P_{Studie}		Zeitraum der Studie vom 01.07.2019 bis 30.06.2020
\mathbf{Q}		Sequenz, in der Daten einer Menge Z in einer festen zeitlichen Reihenfolge angeordnet sind
T		Abtastdauer
T_R		Abtastreserve
V		Kostenfunktion der Identifikation
V_{RMSE}		Kostenfunktion basierend auf dem <i>Root Mean Squared Error</i>
V_{SE}		allgemeine Kostenfunktion des <i>Least-Squares</i> Identifikationsansatzes
X		Signalspektrum
Z		Datenmenge
$Z_{V,\text{Studie}}$		Daten des Versuchsträgers im Studienzeitraum P_{Studie}

a_x	m/s^2	Längsbeschleunigung, Beschleunigung in x-Richtung
a_y	m/s^2	Querbeschleunigung, Beschleunigung in y-Richtung
$a_{y,\text{dyn}}$	m/s^2	Querbeschleunigung, die beim Durchfahren einer Kurve auf den Schwerpunkt wirkt
$a_{y,\text{Rauschen}}$	m/s^2	Querbeschleunigungsanteil durch Sensorrauschen
$a_{y,\text{rot}}$	m/s^2	Querbeschleunigung mit zusätzlichem Rotationsanteil
$a_{y,\text{sen}}$	m/s^2	Sensorwert der Querbeschleunigung
c_E	N/m^2	Kompressionsmodul des Reifengürtels
c_a		Verhältnis der Mantelhöhe zur Reifenbreite
c_b	m	Reifengürteldicke
c_{SW}		vertikale Seitenwanddurchbiegung bei Belastung
$c_{\alpha,v/h}$	N/rad	Schräglaufsteifigkeit der Reifen (vorne/hinten)
d_H	m	Fahrzeughöhe
d_S	m	mittlere Spurweite
d_r	m	Reifenradius
d_w	m	Reifenbreite
e		Fehler, Residuum zweier Vergleichswerte
$f_{\text{id/log/tanh}}$		Aktivierungsfunktion (Identität, logistisch, Tangens hyperbolicus)
g	m/s^2	Gravitationsbeschleunigung ($g = 9,81 \text{ m/s}^2$)
k		Laufvariable der Zeitschritte
l	m	Radstand
$l_{v/h}$	m	Abstand der Vorder-/Hinterachse zum Schwerpunkt CoG
m	kg	Fahrzeugmasse
p	- bzw. s	Datenpaketgröße (als Zahlenwert oder als Zeitdauer)
$p_{a/b}$	%	Gas-/Bremspedalstellung
$s(t)$		kontinuierliches Signal s in Abhängigkeit der Zeit t
$s(t_n)$		Signalwert zum diskreten Zeitpunkt t_n
s_0		unbearbeitetes aufgezeichnetes Signal (nicht äquidistant)
s_a		äquidistantes Signal
$s_{P/Q}$		aufwärts-/abwärtsgetastetes Signal
t	s	Zeitpunkt
u, \mathbf{u}		Systemeingang, -eingänge
v	m/s	Geschwindigkeit
v_x	m/s	Geschwindigkeit in x-Richtung
w		Bandbreite
w_{ROT}		Bandbreite, berechnet mit der <i>Rule of Thumb</i>
y, \mathbf{y}		Systemausgang, -ausgänge
y_E		Modellausgang
y_R		Referenzausgang (Systemausgang plus Störanteil)
y_S		Systemausgang

Griechische Buchstaben:

Symbol	Einheit	Bedeutung
Γ		Anzahl der Datenpunkte bzw. Fahrdauer, zu der das Abbruchkriterium ξ erfüllt wird
Θ		Vektor der Identifikationsparameter
$\hat{\Theta}$		identifizierter Parametersatz (Ergebnis der Identifikation)
$\alpha_{v/h}$	rad	Schräglaufwinkel (vorne/hinten)
β	rad	Schwimmwinkel
δ_H	rad	Lenkradwinkel
δ_v	rad	Lenkwinkel der Vorderachse
ϵ		Störgröße
ϵ_{LD}		Störgrößenvektor der Längsdynamik
ϵ_{QD}		Störgrößenvektor der Querdynamik
η	rad	Querneigungswinkel der Straßenebene
θ	rad	Nickwinkel
σ		Standardabweichung
ξ		Abbruchkriterium der Kullback-Leibler-Divergenz
ρ_M	m	Kurvenradius bezogen auf den Momentanpol
μ		Reibungskoeffizient
φ	rad	Wankwinkel
φ_B	rad	Wankwinkelanteil durch Beladung
φ_{dyn}	rad	dynamischer Wankwinkelanteil, der durch $a_{y,\text{dyn}}$ hervorgerufen wird
φ_{stat}	rad	statischer Wankwinkelanteil aus $\varphi_{\text{stat}} = \eta + \varphi_B$
$\psi, \dot{\psi}$	rad, rad/s	Gierwinkel, Giergeschwindigkeit/-rate
ω	rad/s	(Kreis-)frequenz
ω_a	rad/s	Abtastfrequenz
ω_g	rad/s	Grenzfrequenz

KAPITEL 1

Einleitung

„Das Ziel ist es, Daten in Informationen und Informationen in Erkenntnisse zu verwandeln.“¹

Carly Fiorina, ehemalige CEO von Hewlett-Packard

Daten und die in ihnen enthaltenen Informationen sind in einer immer stärker digitalisierten und vernetzten Welt längst zu einem begehrten Rohstoff geworden. Unternehmen analysieren fortlaufend das Verhalten von Kunden, den Markt sowie das eigene Unternehmen. So können neue Dienste und Produkte angeboten werden oder das eigene Unternehmen an geänderte Gegebenheiten angepasst werden. Dabei spielen die erhobenen Daten die entscheidende Rolle. Viele Innovationen aus den vergangenen zwei Jahrzehnten sind auf die gestiegenen Möglichkeiten zurückzuführen, Personen oder Maschinen dauerhaft zu überwachen und Verhalten mit geeigneten Modellen zu analysieren (bspw. personalisierte Werbung). Die Analyse der vorhandenen Daten, also die Informationsgewinnung, stellt hierbei eine ebenso große Herausforderung dar wie die reine Datengewinnung. Allein die gewachsenen Datenmengen machen es notwendig, ausgereifte Techniken zu verwenden. In diesem Kontext hat sich in den letzten Jahren gezeigt, dass der Bereich der Data Science in nahezu allen Lebensbereichen an Bedeutung gewonnen hat.

1.1 Datennutzung in der Automobiltechnik

Moderne Pkw sind keine Ausnahme, sondern eher ein Paradebeispiel dafür, wie zusätzliche Sensorik in Kombination mit Informationen aus Datenquellen, wie z. B. digitalen Karten, zu Optimierungen oder gänzlich neuen Funktionen führen können. Die fortlaufende Datenerfassung und -auswertung ist Grundlage vieler Funktionen aus dem Bereich

¹vom Autor übersetzt, im Original: „The goal is to turn data into information and information into insight.“

		Beispiele für Anwendungsfälle im Automobil		
Makrokategorie		Heute	2020 – 2025	
Empfindlichkeit der Privatsphäre	Niedrig	 Externe Straßen- und Umgebungsbedingungen (z. B. Eiswarnung auf der Fahrbahn durch das ESP)	 <ul style="list-style-type: none"> • Echtzeit-Navigation 	<ul style="list-style-type: none"> • Vorbeugende Anpassung d. Sicherheitszelle • Live-Straßenbedingungen
		 Technischer Zustand des Fahrzeugs (z. B. Öltemperatur, Meldung technischer Fehlfunktionen)	 <ul style="list-style-type: none"> • Fehler-Diagnose • Automatischer Notruf (e-Call) 	<ul style="list-style-type: none"> • Prädiktive Buchung eines Fahrzeug-services
		 Fahrzeugnutzung (z. B. Geschwindigkeit, Standort, Zuladungsgewicht)	 <ul style="list-style-type: none"> • An Fahrweise angepasste Versicherungsgebühr 	<ul style="list-style-type: none"> • Reduzierung der Entwicklungskosten
		 Persönliche Daten und Vorlieben (z. B. Identität des Fahrers, bevorzugter Radiosender)	 <ul style="list-style-type: none"> • Individuelle Fahrzeueinstellung durch Schlüsselidentifizierung beim Einstieg 	<ul style="list-style-type: none"> • E-Commerce im Fahrzeug • Individualisierte Werbung
		 Direkte Kommunikation aus dem Fahrzeug (z. B. Kalender, Telefon, Mail)	 <ul style="list-style-type: none"> • Sprachsteuerung der Kommunikationskanäle (SMS, Mail) 	<ul style="list-style-type: none"> • Virtuelle Assistent/Concierge-Dienste
	Hoch			

Abbildung 1.1: Einteilung von Fahrzeugdaten in unterschiedliche Klassen sowie Zuteilung dieser Klassen zu zukünftigen Geschäftsfeldern aus McKinsey&Company (2016, S. 16)²

der Fahrerassistenz, für Komfortsysteme oder auch für das hochautomatisierte Fahren. Vielfältige Messpunkte und die Möglichkeit, auch große Datenmengen zu verwalten und auszuwerten, haben im Entwicklungsprozess bei der Analyse des Fahrzeugs aber auch des Fahrerverhaltens enorme Bedeutung erlangt.

Getrieben durch die Trends des hochautomatisierten Fahrens und der Digitalisierung des Pkws steigt die Anzahl verschiedener Datensignale im Pkw. Schätzungen von Capgemini Invent (2020, S. 5) besagen, dass aktuelle Fahrzeuge über mehr als 100 verschiedene Datensignale verfügen. Diese Zahl wird sich mit der nächsten Generation von Fahrzeugen vervielfachen und schätzungsweise auf über 10.000 anwachsen. (Capgemini Invent, 2020) Das Sammeln dieser Daten wird mehr und mehr zur Selbstverständlichkeit (McKinsey&Company, 2016). Das Monetarisierungspotential von Fahrzeugdaten wird in den Analysen der Beratungsfirmen Capgemini Invent (2020) und McKinsey&Company (2016) untersucht. Studien schätzen, dass das Marktvolumen für Fahrzeugdaten im Jahr 2030 auf 80 bis 800 Mrd. \$ (siehe Capgemini Invent (2020, S. 5)) respektive 450 bis 750 Mrd. \$ (siehe McKinsey&Company (2016, S. 7)) ansteigen wird. Neben Automobilherstellern können auch Zulieferer oder Forschungseinrichtungen von den Daten profitieren.

In Abbildung 1.1 sind Fahrzeugdaten in unterschiedliche Klassen, von hoch sensiblen Kundendaten bis zu weniger sensiblen Umgebungsdaten, eingeteilt. Den einzelnen Klassen werden aktuelle und zukünftige Geschäftsfelder zugeordnet. In McKinsey&Company (2016) werden besonders der Mehrwert dieser Daten für die Reduzierung der Entwicklungskosten

²Darstellung vom Autor übersetzt und editiert

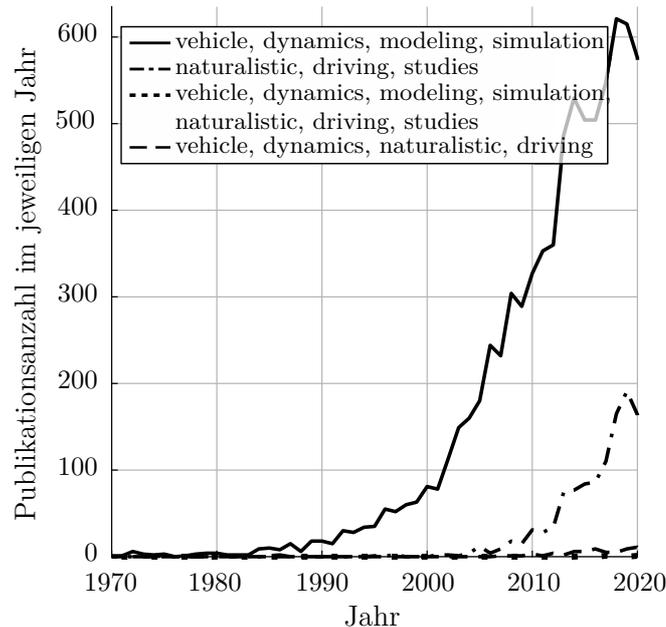


Abbildung 1.2: Literaturrecherche in der Scopus³-Datenbank. Publikationsanzahl zu der Schlagwortsuche: *vehicle, dynamics, modeling, simulation, naturalistic, driving, studies*. Suchanfrage vom 26.04.2021

oder zur Optimierung bestehender Systeme genannt, ohne dabei jedoch den finanziellen Umfang der einzelnen Bereiche genauer zu beschreiben. Zusammenfassend ist bei der aktuellen Entwicklung und aus den genannten wirtschaftlichen Interessen davon auszugehen, dass in den nächsten Jahren zunehmend detaillierte Daten von im Feld befindlichen Pkw für unterschiedlichste Analysen zur Verfügung stehen werden. Es ist möglich, dass weitere Anwendungsfelder für die Daten gefunden werden, die über die in Abbildung 1.1 dargestellten Anwendungsfälle hinausgehen.

Neben der Verwendung von Sensordaten für Funktionen oder Dienste haben Messdaten auch für die Forschung und Entwicklung im automobilen Umfeld eine große Bedeutung. Zwei Forschungsfelder, die an dieser Stelle genannt werden müssen, sind die Analyse und Modellierung der Fahrzeugdynamik sowie sogenannte Naturalistic Driving Studies (Abk.: NDS, für weitere Informationen siehe Abschnitt 2.3). Entsprechende Literaturrecherchen (siehe Abbildung 1.2) zeigen deutlich, dass der Bereich der Fahrzeugdynamikmodellierung seit spätestens den 1980er-Jahren in den Fokus der Forschung gerückt ist. Detaillierte und genaue Fahrdynamikmodelle werden u. a. für die Entwicklung von Regelsystemen (ESP, ABS) oder für das hochautomatisierte Fahren benötigt. Auch dienen sie längst schon zur Entwicklung der Fahrdynamik bis in den Grenzbereich. Zur Identifikation der Modellparameter klassischer theoretischer Modelle, aber oft auch bei den in jüngerer Vergangenheit in den Fokus gerückten experimentellen Modellen, werden Messungen benötigt. Diese Messungen zur Identifikation oder Validierung der Fahrdynamikmodelle werden meist in standardisierten Fahrversuchen (ISO 15037-1) erhoben. Ziel dieser Versuche ist

es, mit maximaler Versuchskontrolle eine gezielte Anregung verschiedener Fahrzustände zu ermöglichen. Das Fahrzeug wird dabei oft an die physikalischen Grenzen der Fahrzeugdynamik gebracht. Hierfür kommt ein mit spezieller Messtechnik ausgestatteter Versuchsträger zum Einsatz. Die definierten Manöver (z. B. Spurwechsel, Lenkwinkelsprung) werden von Testfahrern durchgeführt. Diese meist kurzen, aber extremen Manöver sind häufig keinen realen Fahrsituationen nachempfunden, sondern sie sind so definiert, dass sie das Fahrzeug an den Rand seiner Leistungsfähigkeit bringen. In realen Fahrten sind diese Manöver äußerst selten zu beobachten. Der Vorteil dieses Vorgehens liegt auf der Hand. Die Versuche liefern einen reproduzierbaren und vorhersagbaren Informationsgehalt und sind in ihrer Dauer gut planbar. Die kurzen Versuchszeiten ermöglichen es zudem, dass Messungen bei Bedarf mit leicht modifizierten Set-ups wiederholt werden können.

Der große Vorteil der Standardmanöver, die Erzeugung sehr gezielter Situationen, ist für einige Modellierungstechniken eine Herausforderung. Es können nur begrenzt und unter größtem Aufwand umfangreiche Datenmengen erzeugt werden, die auch einen breiten Bereich der Fahrzeugdynamik abdecken. Solche Datenmengen sind etwa für datengetriebene Modellierungstechniken (bspw. Künstliche Neuronale Netze), wie sie zunehmend in der automobilen Modellbildung verwendet werden (für Beispiele siehe Abschnitte 2.6), erforderlich. Auch durch diese Ansätze rücken Daten aus Normalfahrten stärker in den Fokus zur Fahrdynamikmodellierung. Einige der im Fahrversuch aufgezeichneten und zur Modellierung notwendigen Messgrößen werden im Fahrzeug bereits seit Jahren erfasst. Die starke Marktdurchdringung der sicherheitsrelevanten Fahrerassistenzsysteme ABS und ESP machen fahrdynamische Messgrößen in heutigen Fahrzeuggenerationen unverzichtbar. Trotz der großen Anzahl von Fahrzeugsensoren und der Möglichkeit, Daten aus dem realen Fahrbetrieb zu sammeln, haben nur wenige Forschungsprojekte versucht, Daten aus alltäglichen Fahrten für die Analyse der Fahrzeugdynamik oder die Parameteridentifikation für Fahrzeugmodelle zu verwenden und so Entwicklungskosten zu reduzieren.

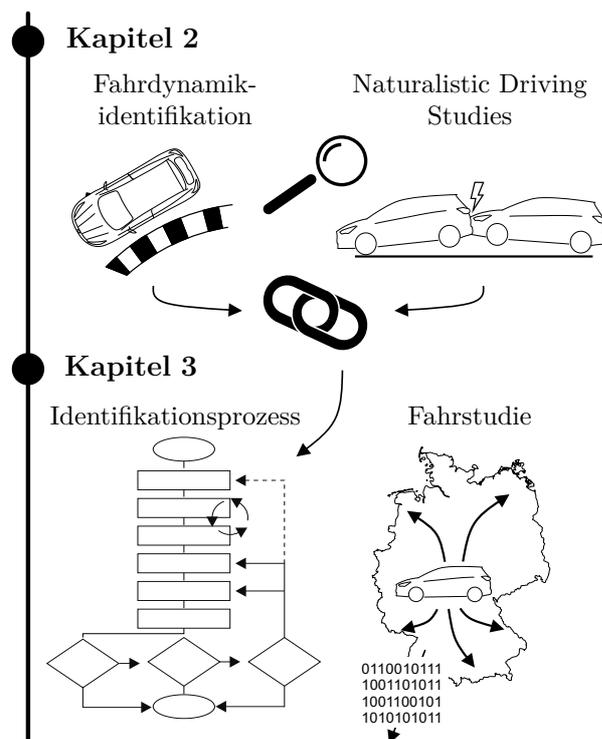
Insbesondere kleinere Organisationen, wie universitäre Einrichtungen, können von Fahrdaten aus alltäglichen Fahrten profitieren. Ein Fahrversuch ist in seiner Durchführung sehr aufwendig und kostspielig. Insbesondere der Zugriff auf die notwendige Infrastruktur (Teststrecken, spezielle Messtechnik) ist für kleinere Organisationen häufig nicht gegeben, sodass eine Datenbasis aus alltäglichen Fahrten mitunter die einzige Möglichkeit darstellt an reale Fahrdaten zu gelangen. Eine nicht kommerziell getriebene Forschung könnte zusätzlich die Entwicklung in der Industrie weiter stimulieren und für neue Methoden und Funktionen verantwortlich sein.

Seit den 2000er-Jahren wird mithilfe von NDS verstärkt das Verhalten des Fahrers bei alltäglichen Fahren untersucht. Diese Studien haben meist zum Ziel, das tägliche Handeln und Verhalten der Fahrer zu beobachten. Die Fahrzeugdynamik ist hierbei bislang nicht betrachtet worden. Dies ist auch bei einer Literaturrecherche in Abbildung 1.2 deutlich sichtbar, wenn die Kombination von Fahrzeugdynamik und NDS überprüft wird. Die Verfügbarkeit der Sensordaten im modernen Pkw legt nahe, dass auch die täglich erhobenen Daten einen Mehrwert für die Analyse und zur Modellierung der Fahrzeugdynamik liefern können. Untersuchungen, die im Rahmen des europäischen Forschungsprojekt DRE-

AMS4CARS (2017) entstanden sind, demonstrieren, dass die Identifikation der Fahrdynamik mit Fahrdaten aus dem öffentlichen Straßenverkehr gelingen kann. Ingenieure der Marke Fiat sind in der Nähe von Turin (Italien) auf einer definierten Strecke auf öffentlichen Straßen zwei Runden von jeweils 50 km gefahren und haben dabei fahrdynamische Größen erfasst. Diese wurden zur Identifikation physikalischer Modellparameter genutzt (für weitere Informationen siehe Abschnitt 2.6.2). Aufgrund der hohen Versuchskontrolle während der Datenaufzeichnung und der geringen Größe des Datensatzes kann dieser nur beschränkt mit naturalistischen Daten von Privatfahrzeugen – Fahrdaten aus alltäglichen Fahrten mit minimaler Versuchskontrolle und unverfälschtem natürlichen Probandenverhalten – verglichen werden. Insbesondere konnte im Projekt DREAMS4CARS (2017) anhand der Daten keine Aussage darüber getroffen werden, welche Informationen hinsichtlich der Fahrdynamik aus naturalistischen Fahrdaten gewonnen werden können. Die Kernfrage dabei lautet, wie gut ein Modell auf der Grundlage von Daten aus Alltagsfahrten werden kann. Ein zweiter, für die Praxis sehr entscheidender Aspekt ist die Abschätzung der notwendigen Studiendauer, um über ungeplante Fahrten genügend Daten zur Fahrdynamikmodellierung zu sammeln. Trotz der scheinbar großen Potentiale sind beide Punkte methodisch noch wenig beleuchtet.

1.2 Gliederung der Arbeit

Die vorliegende Arbeit ist in mehrere Teile gegliedert. Neben der Einleitung und der abschließenden Zusammenfassung wird in fünf Schritten die wissenschaftliche Methode entwickelt und neu gewonnene Erkenntnisse präsentiert.

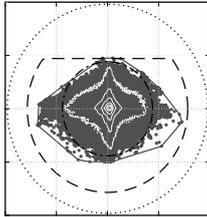


In Kapitel 2 wird eine Einführung in die Thematik der Fahrdynamikidentifikation und NDS gegeben. Es werden relevante Beiträge zum wissenschaftlichen Stand vorgestellt, die Forschungslücke identifiziert und das Forschungsvorhaben sowie der wissenschaftliche Beitrag dieser Arbeit erläutert.

Im Anschluss wird die Methode dieser Arbeit entwickelt. Die in Kapitel 2 vorgestellten Forschungsfelder werden zusammengeführt und der existierende Identifikationsprozess wird für die Anforderungen einer explorativen Studie mit langen Laufzeiten angepasst. Eine Fahrstudie zur Analyse der Methode wird ausgelegt.

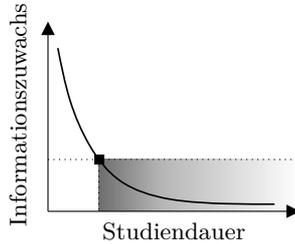
Kapitel 4

Beobachtbare Zustände
in Alltagsfahrten



G-G-Diagramm

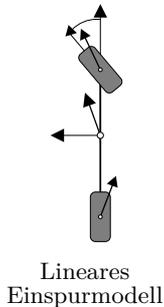
Adäquate Datenmenge



In Kapitel 4 wird analysiert, welche fahrdynamischen Beobachtungen in naturalistischen Fahrten gemacht werden können, zudem wird das Kriterium der Adäquanz, zur Bestimmung einer idealen Studiendauer, ausgewertet. Die Studiendaten werden hinsichtlich ihres Informationsinhaltes untersucht.

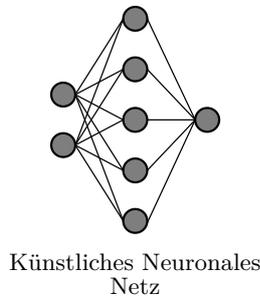
Kapitel 5

Theoretisches Modell



Lineares
Einspurmodell

Experimentelles Modell

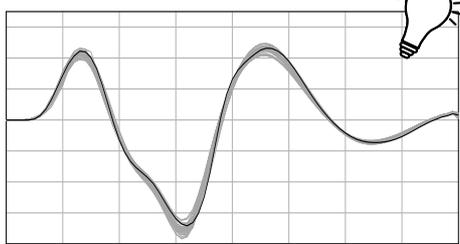


Künstliches Neuronales
Netz

Die Identifikation der Fahrdynamik, am Beispiel der Querdynamik, wird in Kapitel 5 an einem theoretischen sowie an einem experimentellen Modell durchgeführt. Der Einfluss des Datenumfanges sowie des Informationsinhaltes wird in mehreren Identifikationsdurchläufen mit verschiedenen Datensätzen präsentiert. Eine Methode zur Segmentierung von Fahrten in verschiedene Fahrereignisse wird vorgestellt.

Kapitel 6

Validierung



Die identifizierten Modelle und Parametersätze aus Kapitel 5 werden für verschiedene Anwendungsszenarien validiert. Der Einfluss der Datenmenge auf die Modellgenauigkeit sowie Unterschiede zwischen theoretischem und experimentellem Modell werden untersucht und dargestellt. Die Potentiale naturalistischer Fahrdaten für Identifikationszwecke werden umfassend diskutiert.

Abschließend werden in Kapitel 7 die wesentlichen Erkenntnisse zusammengefasst und es wird ein Ausblick gegeben, welche Anwendungsfelder zukünftig von der vorgestellten Methode profitieren können.

KAPITEL 2

Grundlagen

Die vorliegende Arbeit untersucht die Potentiale naturalistischer Fahrdaten für die Identifikation der Fahrdynamik. Zunächst wird der aktuelle Stand hinsichtlich der Modellierung und Identifikation der Fahrdynamik sowie der Naturalistic Driving Studies dargestellt. Ferner wird der wissenschaftliche Stand hinsichtlich des Forschungsvorhabens diskutiert und der wissenschaftliche Beitrag dieser Arbeit vorgestellt.

2.1 Grundlagen der Systemanalyse und Identifikation

Die vorliegende Arbeit leistet einen Beitrag zur Identifikation. Bevor die in dieser Arbeit vorgestellten Neuerungen präsentiert werden, werden zunächst die verwendeten Begriffe näher erläutert und ihr Zusammenhang dargelegt.

2.1.1 Systemanalyse

Modelle sind entsprechend des technischen Bezuges gemäß der Richtlinie VDI 2206 als physikalisch-mathematische Abbilder eines technischen Elements oder Systems definiert. Diese Definition eines Modells bezieht sich insbesondere auf mechatronische Systeme und weicht vom Modellbegriff anderer Domänen ab (vgl. VDI 4465). Modelle bilden die Wirklichkeit oder reale Wirkzusammenhänge in vereinfachter Form ab (VDI 2206). Gemäß ISERMANN (1992) ist die Systemanalyse der übergeordnete Prozess, an dessen Ende ein Modell des analysierten Systems steht. Die Modellbildung ist Teil der Systemanalyse. An den Modellbildungsprozess werden unterschiedliche Anforderungen gestellt (u. a. Genauigkeit, hinreichende Abbildung der Realität). Genügt das Modell diesen Vorgaben, so ist die Modellbildung abgeschlossen (VDI 2206). Das Modell muss so aufgebaut und

gestaltet sein, dass eine definierte Anregung der Systemeingänge des Referenzsystems zu gleicher Reaktion bzw. zu gleichen Modellausgängen führt. Eine absolute Übereinstimmung von System und Modell für physikalische Systeme ist nur theoretisch erreichbar. In der Systemanalyse wird zwischen der theoretischen und der experimentellen Analyse unterschieden (ISERMANN, 1992). In Abbildung 2.1 ist der schematische Ablauf einer Systemanalyse dargestellt.

Bei der theoretischen Analyse wird basierend auf physikalischen Zusammenhängen das System analysiert, wobei die mathematischen Systemgleichungen physikalische Gesetzmäßigkeiten abbilden (ISERMANN, 1992). Hierfür werden in der Regel vereinfachende Annahmen getroffen, um die Modellbildung zu ermöglichen oder den Aufwand zu begrenzen. Die Systemgleichungen werden durch Bildung von Bilanzgleichungen, physikalisch-chemischen Zustandsgleichungen, oder phänomenologischen Gleichungen aufgestellt (siehe Abbildung 2.1). Es werden quantitative Informationen aus der Geometrie, aus Stoffkonstanten und empirischen Beobachtungen gewonnen (VDI 2206). Das Resultat ist ein Gleichungssystem aus differential-algebraischen Gleichungen, die das theoretische Modell bilden. Dieses besteht wiederum aus einer Struktur und Parametern. Die Parameter sind physikalische Größen wie Masse oder Widerstände (ISERMANN, 1992).

Die experimentelle Analyse bildet den zweiten Pfad der Systemanalyse und wird auch (System-)Identifikation genannt. Die mathematische Systemstruktur sowie die mathematischen Systemgleichungen werden anders als bei der theoretischen Modellbildung nicht aus physikalischen Gesetzen, sondern aus Messungen, den sogenannten Experimenten, gewonnen. Falls vorhanden, sind A-priori-Kenntnisse zum System dabei der Ausgangspunkt. Diese im Vorfeld verfügbaren Erkenntnisse können bei der Planung der Experimente helfen. Sie können etwa aus der theoretischen Modellbildung oder auch aus vorangegangenen Messungen stammen. Beispiele für A-priori-Kenntnisse sind Kenntnisse zur Modellstruktur, zu den Systemein- und -ausgängen oder etwa zu geeigneten Systemanregungen. Umso mehr A-priori-Wissen vorhanden ist, desto weniger muss während der Experimente generiert werden. (ISERMANN, 1992)

Im Zentrum der experimentellen Systemanalyse steht das Experiment selbst. Dieses kann mitunter zeitlich aufwendig und sehr kostenintensiv sein. Der Erfolg einer experimentellen Systemanalyse ist direkt gekoppelt an die Qualität des Experiments. Die einzelnen Bereiche des Experiments werden in Abschnitt 2.1.2 vorgestellt und beschrieben. Innerhalb des Experiments wird das zu untersuchende System angeregt und dessen Eingänge sowie dessen Ausgänge messtechnisch erfasst.

Auf das Experiment folgt die Modellbildung. Bei Modellen mit unbekannter Struktur, den nicht parametrischen Modellen, wird das physikalische Übertragungsverhalten mittels mathematischer Beschreibungen identifiziert. Parametrische Modelle hingegen lassen sich als Gleichungen, in denen die Parameter explizit bekannt sind, beschreiben. Folglich ist die Anzahl der Parameter endlich. Für Parameter von theoretischen Modellen stehen die Parameter im Bezug zu physikalischen Größen, wie der Masse oder einer Länge. Der Vollständigkeit halber sei erwähnt, dass es auch Modelle gibt, bei denen die Beziehung zwischen Systemeingang und Systemantwort nicht durch Parameter, sondern z. B. anhand

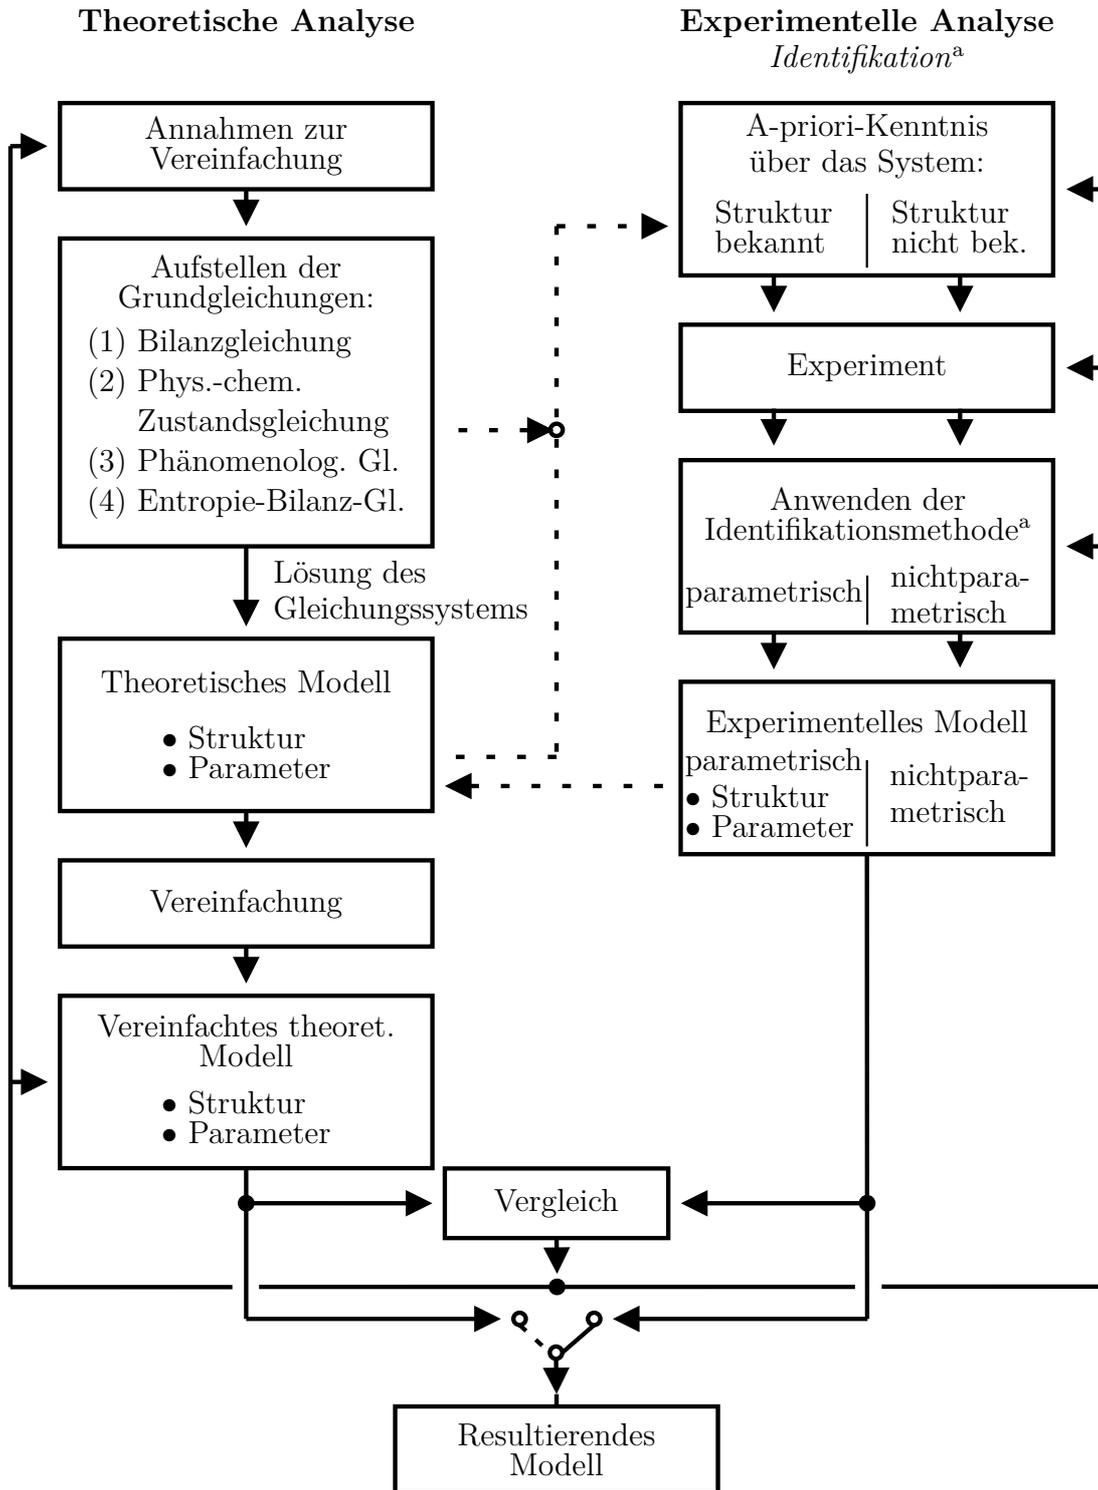


Abbildung 2.1: Systemanalyse nach ISERMANN (1992, S. 4). Die Systemanalyse wird in zwei Pfade, die theoretische und die experimentelle Analyse, aufgeteilt.

^a Änderungen gegenüber dem Original

von Tabellen oder Kennlinien bestimmt werden. Solche nicht-parametrischen Modelle sind nicht Gegenstand dieser Arbeit. (ISERMANN, 1992)

Sofern beide Modellbildungsverfahren angewandt werden, können theoretisches und experimentelles Modell am Ende der Systemanalyse verglichen und hieraus Rückschlüsse auf die getroffenen Annahmen vom Beginn gezogen werden. Der gesamte Prozess ist iterativ und wird so lange durchlaufen, bis die gewünschte Modellgüte erreicht ist.

In ISERMANN (1992) wird beschrieben, dass die Systemanalyse in der Regel weder rein theoretisch noch rein experimentell ist. Vielmehr ist sie eine Kombination der beiden Ansätze, welche durch den Anwendungsfall und das System selbst vorgegeben ist. Eine Kombination beider Pfade ist in Abbildung 2.1 durch eine gestrichelte Linie dargestellt. Hierbei wird zunächst die Struktur des Modells mithilfe der theoretischen Analyse aufgestellt. Die unbekannt Parameter werden durch Vergleich von Messungen am realen System und an dem Modell bestimmt. Dieser Modellierungsansatz hat eine hohe Relevanz für die vorliegende Arbeit (siehe Kapitel 5). Die Entscheidung, welche Modellierungsart gewählt wird, ist abhängig vom jeweiligen Anwendungsfall. Einige bedeutende Charakteristika der Modelle werden im Folgenden genannt (ISERMANN, 1992):

Theoretisches Modell:

- Validierte Modellstrukturen können auf ähnliche Fragestellungen übertragen werden.
- Die theoretische Beschreibung liefert grundsätzlich mehr Informationen über das System. Zusätzlich zum identifizierten Ein-/Ausgangverhalten werden weitere Informationen zum System und dessen Zusammenhänge abgebildet (die physikalische Größe der Parameter, innere Zustände sowie die physikalische Struktur).
- Die Modellparameter müssen a priori sinnvoll festgelegt werden.
- Physikalische Modellierungsansätze machen Vereinfachungen notwendig. Gleichzeitig wird die Genauigkeit der Modelle durch Vereinfachung zwangsläufig begrenzt.

Experimentelles Modell:

- Die Modellgüte ist stark von der Qualität der Datenbasis und dessen Eignung für die Anwendung abhängig (u. a. Abhängigkeit der Modellgenauigkeit vom Messfehler).
- Experimentelle Modelle beschreiben ein reines Ein-/Ausgangverhalten. Die Parameter sind Zahlenwerte ohne physikalische Bindung. Die Beschreibung innerer Systemzustände ist nicht möglich.
- Das identifizierte Modell ist nur für das untersuchte System und die definierten Betriebszustände gültig, in diesen jedoch häufig sehr genau.
- Eine Übertragbarkeit des Modells auf andere Fragestellungen ist in der Regel nicht möglich.

2.1.2 Parameteridentifikation

Unter dem Begriff der Systemidentifikation wird die Ermittlung des zeitlichen Verhaltens eines Systems unter Zuhilfenahme experimenteller Daten verstanden (ISERMANN, 1992). Die Begriffe Systemidentifikation und Identifikation werden hierbei häufig als Synonyme verwendet (siehe Systemanalyse in Abschnitt 2.1.1 und in Abbildung 2.1). Abhängig vom Identifikationsvorhaben kann die Begrifflichkeit weiter unterteilt und spezifiziert werden. Die Ermittlung einer Modellstruktur wird als Modellidentifikation und die Bestimmung von Parametergrößen als Parameteridentifikation bezeichnet. In dieser Arbeit werden u. a. Parametergrößen bekannter Modellstrukturen identifiziert.

Die bei einem Experiment gemessenen Signale werden verwendet, um das Verhalten des Systems mithilfe von mathematischen Modellen zu beschreiben. Das Residuum bzw. die Abweichung zwischen dem realen System (der Referenz) und seinem mathematischen Modell wird als Fehler bezeichnet und soll so gering wie möglich sein. Die Identifikation ist Teil der Systemanalyse aus Abschnitt 2.1.1 und beschreibt den rechten Ast aus Abbildung 2.1. (ISERMANN, 1992)

Die Identifikation von Systemen ist ein gut erforschter Teilbereich der Modellbildung und Inhalt vieler Veröffentlichungen. Einige methodisch grundlegende Veröffentlichungen in diesem Themenfeld sind die von LJUNG (1987), SÖDERSTRÖM, STOICA (1989) und ISERMANN (1992). Die genannte Literatur steht beispielhaft für eine Reihe weiterführender Literatur. Die einzelnen Arbeiten sind sich in ihrem methodischen Vorgehen sehr ähnlich. Exemplarisch wird der Identifikationsprozess parametrischer Modelle nach SÖDERSTRÖM, STOICA (1989) in Abbildung 2.2 dargestellt. Dieser ist in fünf Schritte gegliedert:

1. Zu Beginn steht die Versuchsplanung. In diese sollte möglichst viel A-priori-Wissen über das System und das dazugehörige Verhalten einfließen, damit der experimentelle Aufwand klein und der Erkenntnisgewinn gleichzeitig groß ist.
2. Im zweiten Schritt folgen die Durchführung des Experiments und die dazugehörige Datenaufzeichnung.
3. Für die Auswahl der Modellstruktur werden die aufgezeichneten Daten und etwaiges A-priori-Wissen genutzt.
4. Für parametrische Modelle werden die Parametergrößen mittels Schätzmethoden bestimmt.
5. Im letzten Schritt muss das identifizierte Modell validiert werden.

Aufgrund des explorativen Charakters einer experimentellen Identifikation ist ein iteratives Vorgehen bei der Identifikation üblich. Die einzelnen Prozessschritte ermöglichen die Rückkehr zu vorherigen Prozessschritten, bis hin zu einer erneuten Versuchsplanung. Die Rückkehr zu vorherigen Schritten wird notwendig, wenn aufgrund neu gewonnenem Systemverständnis weitere Experimente notwendig werden, mit den gewählten Methoden nicht die gewünschte Modellgüte erreicht wird oder das identifizierte Modell nicht valide ist.

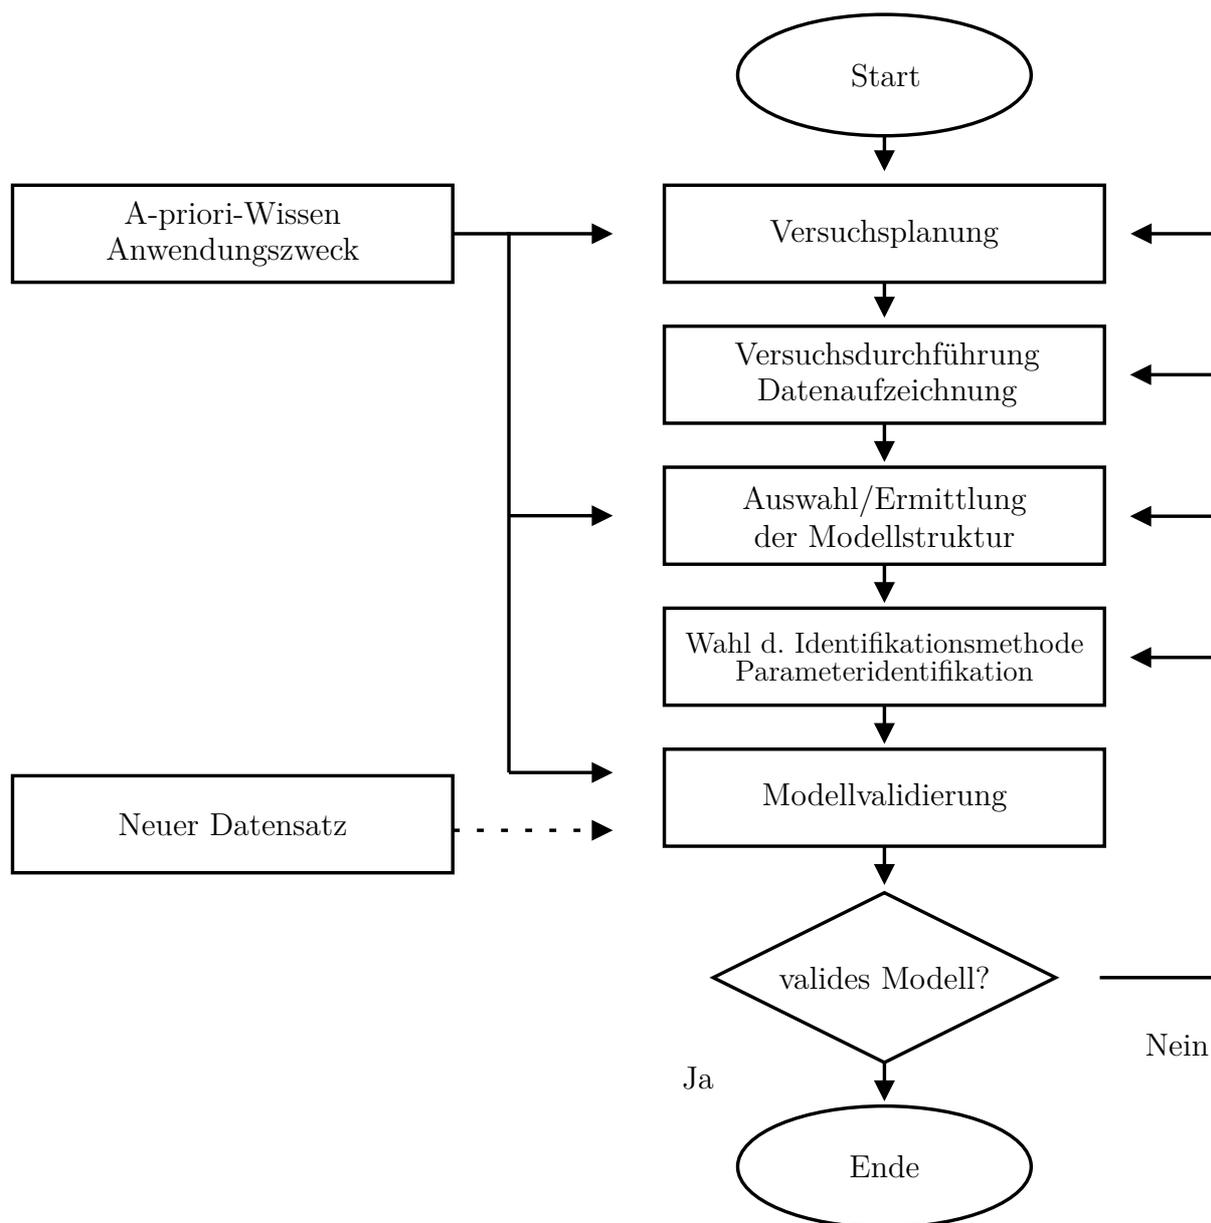


Abbildung 2.2: Ablauf einer Identifikation parametrischer Modelle nach SÖDERSTRÖM, STOICA (1989, S. 6), Darstellung vom Autor übersetzt

Versuchsplanung/-durchführung

Wie auch in der Literatur zu dem Thema, werden im Rahmen dieser Arbeit die Begriffe Versuch und Experiment synonym verwendet. Am Beginn des Identifikationsprozesses (siehe Abschnitt 2.1.2) steht die Versuchsplanung, gefolgt von der Versuchsdurchführung. Die Versuchsplanung umfasst die Planung aller Schritte, die zur Durchführung eines Versuchs notwendig sind. Hierunter fallen die Auswahl der Messgrößen und deren sensorische Erfassung, die Anregung des Systems und die Erstellung eines Versuchsplans. Die Versuchsdurchführung beinhaltet die eigentliche Durchführung des Experiments sowie

die Verarbeitung der anfallenden Messdaten. Sie sollte bereits bei der Versuchsplanung berücksichtigt werden. Die Ausprägung und der Aufwand der Versuchsplanung und -durchführung sind anwendungsspezifisch. Ein Beispiel aus der Automobilindustrie wird in Abschnitt 2.2.4 gegeben.

Im folgenden Abschnitt wird ausschließlich auf die generellen Aspekte der Versuchsplanung und -durchführung eingegangen. In LJUNG (1987) wird beschrieben, dass das Ziel der Versuchsplanung die Maximierung des Informationsgehaltes der Daten des durchgeführten Experiments ist. Hierbei müssen häufig bestimmte Rahmenbedingungen beachtet werden, die den Handlungsspielraum einschränken. LJUNG (1987) nennt in seiner Arbeit als Beispiele, dass die Anzahl der Versuche begrenzt sein kann, Messungen ausschließlich im natürlichen Betrieb durchgeführt werden können oder Störeinflüsse nicht im gewünschten Maße eingegrenzt werden können. Nach NELLES (2011) teilt sich die Versuchsplanung auf in die Fragen, welche Eingänge auf den Ausgang wirken und wie deren Wirkweise ist. Für die Identifikation ist das Wissen zu den Systemeingängen und -ausgängen notwendig. Diese müssen während der Versuche sensorisch erfasst werden. Bei mechanischen Systemen mit Einblick in physikalische Zusammenhänge sind die notwendigen Eingänge und Ausgänge oft leicht erkennbar. Ansonsten können diese methodisch bestimmt werden (NELLES, 2011).

Idealerweise kann die zu identifizierende Dynamik ausreichend durch die Eingänge angeregt werden (ISERMANN, 1992). In NELLES (2011) wird die besondere Bedeutung der Eingangssignale für das betrachtete System bei der Identifikation hervorgehoben. Eingangssignale sind die einzige Möglichkeit, den Prozess zu beeinflussen, um Informationen zu dessen Verhalten zu generieren.

Eine geeignete Wahl der Eingangssignale erfordert Vorkenntnisse über den Prozess und den Modellzweck. Es wird zwischen den natürlich im Betrieb auftretenden Eingangssignalen und künstlich erzeugten Signalen unterschieden. Dabei ist naheliegend, dass für eine gezielte Systemanregung künstliche Signale bessere Eigenschaften besitzen. Vorgaben für ein geeignetes Design künstlicher Eingänge kann der Literatur aus Abschnitt 2.1.2 sowie ISERMANN, MÜNCHHOF (2011) und NELLES (2011) entnommen werden.

Wie oben beschrieben, kann die Wahl der Eingänge in der realen Anwendung aufgrund von Betriebsbedingungen beschränkt sein. Falls das System nicht gezielt angeregt werden kann, sollte der Datensatz zur Identifikation so gewählt werden, dass die Daten möglichst repräsentativ sind. Eine solche Auswahl erfordert wiederum ausreichend Wissen über das System. Bei der Modellbildung ohne A-priori-Wissen sind die Messungen die einzige Informationsquelle zum Systemverhalten. Jegliche Systemdynamik, welche innerhalb des Datensatzes nicht dargestellt wird, kann durch das Modell nicht beschrieben werden. Die Wahl der Eingänge beeinflusst somit die erreichbare Modellgüte maßgeblich. (NELLES, 2011)

Parameteridentifikation

In dieser Arbeit werden parametrische Modellstrukturen genutzt, die in vergleichbaren Anwendungsfällen zu sehr guten Ergebnissen geführt haben (siehe Kapitel 5). Die Parametergrößen dieser parametrischen Modelle werden mittels Parameteridentifikation bestimmt. Die Signale werden als zeit- und wertediskrete Zeitreihen betrachtet. Für die Modellstruktur, von der angenommen wird, dass diese das System beschreibt, wird die Parameterkombination gesucht, die das System bestmöglich in Bezug auf die Minimierung einer Kostenfunktion abbildet (STRUTZ, 2011).

Das schematische Vorgehen zur Bestimmung der Parametergrößen ist in Abbildung 2.3 dargestellt. Das System wird durch die Systemeingänge \mathbf{u} zum Zeitschritt k

$$\mathbf{u}_k = [u_{1,k}, \dots, u_{m,k}] \quad k \in \mathbb{N}^+ \quad (2.1)$$

angeregt. Der zugehörige Vektor \mathbf{y}_S der Systemausgänge zum Zeitschritt k wird mit

$$\mathbf{y}_{S,k} = [y_{S,1,k}, \dots, y_{S,m,k}] \quad (2.2)$$

beschrieben. Für reale Systeme werden die Messungen der Signale durch Mess- und Systemrauschen ϵ_k gestört. Rauschanteile am Eingang werden in Anlehnung an ISERMANN, MÜNCHHOF (2011) als vernachlässigbar klein angenommen und die gemessenen Systemausgänge

$$\mathbf{y}_{R,k} = \mathbf{y}_{S,k} + \epsilon_k \quad (2.3)$$

können als Summe der Systemausgänge \mathbf{y}_S , welche aus der Anregung resultieren, und zusätzlichem Rauschanteil ϵ zusammengefasst werden. Das Modell ist schematisch parallel zum System verschaltet. Die Eingänge in das Modell sind die gemessenen Systemeingänge \mathbf{u}_k . Die Modellausgänge werden mit $\mathbf{y}_{E,k}$ bezeichnet.

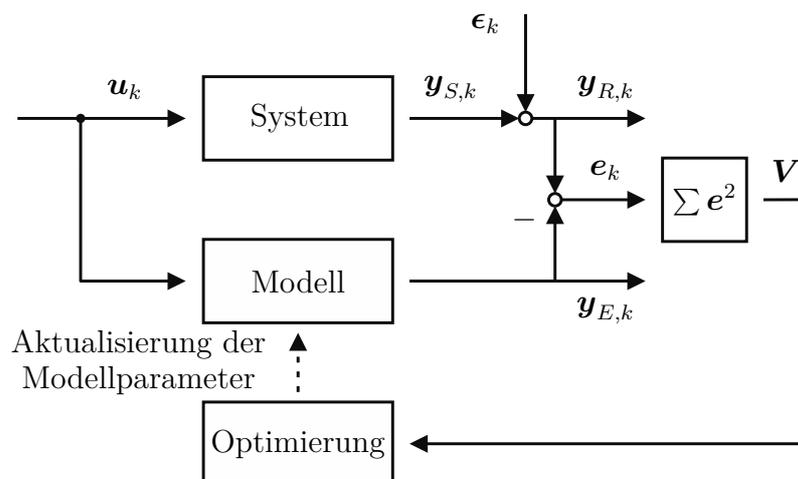


Abbildung 2.3: Signalfuss bei der Parameteridentifikation von Modellen mit Zeithensignalen in Anlehnung an NELLES (2011)

Das Modellverhalten

$$\mathbf{y}_{E,k} = f(\mathbf{u}_k, \boldsymbol{\Theta}) \quad (2.4)$$

wird durch die Funktion $f(\mathbf{u}_k, \boldsymbol{\Theta})$ beschrieben und ist abhängig von sowohl den Eingängen \mathbf{u}_k als auch den Parametern

$$\boldsymbol{\Theta} = [\Theta_1, \dots, \Theta_r]. \quad (2.5)$$

Die Abweichung zwischen einem einzelnen gemessenen Systemausgang $y_{R,i,k}$ zum Zeitschritt k und dem zugehörigen Modellausgang $y_{E,i,k}$

$$e_{i,k} = y_{R,i,k} - y_{E,i,k} \quad (2.6)$$

wird als Fehler $e_{i,k}$ bezeichnet. Die Fehlerwerte der einzelnen Zeitschritte sowie Ausgänge können in einem Fehlervektor

$$\mathbf{e}_k = [e_{1,k}, \dots, e_{m,k}] \quad (2.7)$$

zusammengefasst werden. Die Fehler wiederum werden an eine Kostenfunktion V übergeben. Die Parameter werden so angepasst, dass die Kostenfunktion V in der Optimierungsaufgabe

$$\hat{\boldsymbol{\Theta}} = \underset{\boldsymbol{\Theta}}{\operatorname{argmin}} V(\boldsymbol{\Theta}) \quad (2.8)$$

minimiert wird. Bei der Definition der Kostenfunktion V hat der Anwender große Freiheiten und kann diese nach seinen Anforderungen (linear oder nichtlinear, mit/ohne Nebenbedingung) auslegen. Zur Lösung des Optimierungsproblems kommen häufig numerische Verfahren zum Einsatz. Teilweise kann eine analytische Lösung des Optimierungsproblems gefunden werden. Ansätze zur Bestimmung der analytischen Lösung können ISERMANN, MÜNCHHOF (2011), STRUTZ (2011), NELLES (2011), SÖDERSTRÖM, STOICA (1989) entnommen werden.

Methode der kleinsten Fehlerquadrate

Eine Methode, welche für diskrete Zeitreihen etabliert ist, ist die Methode der kleinsten Fehlerquadrate (engl.: *Least Squares*) (STRUTZ, 2011). Sie wird zur Berechnung der Kostenfunktion in dieser Arbeit genutzt.

Für Systeme mit nur einem Systemausgang ($m = 1$) werden die Fehlerwerte der einzelnen Zeitschritte zu einer Kostenfunktion

$$V_{\text{SE}}(\boldsymbol{\Theta}) = \sum_{k=1}^N e_k^2 \quad (2.9)$$

quadriert und aufsummiert. Die Fehlermetrik der Wurzel der mittleren Fehlerquadratsumme (engl.: *Root Mean Squared Error*, Abk.: RMSE), mit der Kostenfunktion

$$V_{\text{RMSE}}(\boldsymbol{\Theta}) = \sqrt{\frac{1}{N} \sum_{k=1}^N e_k^2}, \quad (2.10)$$

ist eine häufig genutzte Adaptionen der Methode der kleinsten Fehlerquadrate.

2.2 Identifikation in der Fahrzeugdynamik

Die Identifikation in der Fahrzeugdynamik ist umfassend dokumentiert. Im folgenden Abschnitt werden die für diese Arbeit relevanten Grundlagen dargestellt.

2.2.1 Dynamik eines Personenkraftfahrzeugs

In der vorliegenden Arbeit werden die Begriffe Pkw, Kraftfahrzeug und Fahrzeug synonym verwendet und beziehen sich alle auf straßengebundene Personenkraftfahrzeuge. Die Beschreibung der Fahrzeugbewegung im Raum ist in ISO 8855 festgelegt. In Abbildung 2.4 sind die Bewegungsfreiheitsgrade des Fahrzeugaufbaus und die Bezugssysteme eingezeichnet. Das ortsfeste Koordinatensystem $\mathbf{K}_E = \{O_E; x_E, y_E, z_E\}$ ist an der Horizontalebene ausgerichtet. Diese liegt im inertialen Bezugssystem (hier: der Erde) und steht senkrecht zur Richtung der Schwerkraft g . Der Ursprung O_E des ortsfesten Koordinatensystems \mathbf{K}_E liegt in der Horizontalebene. Die x_E - und y_E -Achse sind parallel zur Horizontalebene und die z_E -Achse zeigt nach oben. Die Lage des Ursprungs O_E innerhalb der Horizontalebene kann beliebig gewählt werden. Das fahrzeugfeste Koordinatensystem $\mathbf{K}_V = \{O_V; x_V, y_V, z_V\}$ hat seinen Ursprung im Fahrzeugreferenzpunkt. Dieser kann abhängig von der Anforderung gewählt werden. Eine häufige Wahl ist der Schwerpunkt CoG . Die x_V -Achse ist entlang der Fahrzeuglängsachse nach vorne und parallel zur Fahrzeuglängsmittlebene ausgerichtet. Die y_V -Achse zeigt in Fahrzeugrichtung nach links und steht senkrecht zur Fahrzeuglängsmittlebene. Die z_V -Achse zeigt nach oben und ist orthogonal zu der x_V -Achse und y_V -Achse. (ISO 8855)

Die Fahrzeugdynamik befasst sich mit der Dynamik von Kraftfahrzeugen und ist folglich ein Teilgebiet der Fahrzeugmechanik. Sie beschreibt unter Berücksichtigung der zugrunde liegenden Naturgesetze die Bewegungsvorgänge von Fahrzeugen. Die Bewegungen entstehen als Reaktion von auf das Fahrzeug einwirkenden Kräften und Momenten. (SCHRAMM, HILLER et al., 2018)

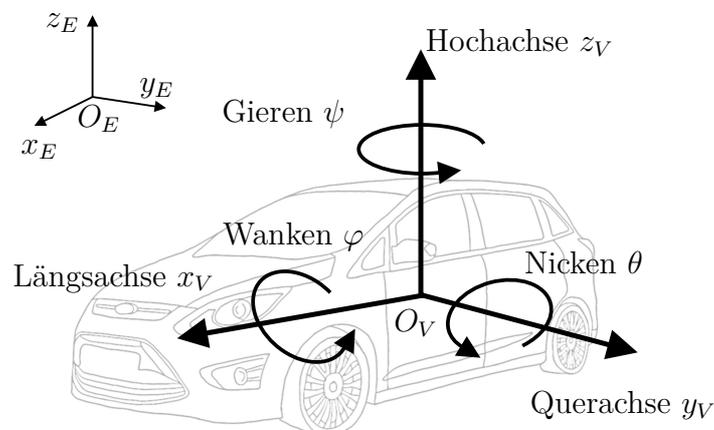


Abbildung 2.4: Fahrzeugbewegung im Raum nach ISO 8855

Bezogen auf das Gesamtfahrzeug wird zwischen Bewegungen entsprechend der drei Achsen im Raum unterschieden. Damit hat ein Fahrzeug als Starrkörper betrachtet sechs Freiheitsgrade. Bewegungsvorgänge in Fahrzeuginnenrichtung, hierzu zählen Beschleunigen und Abbremsen des Fahrzeugs, werden als Längsdynamik bezeichnet. Sie wird maßgeblich durch die antreibenden Kräfte des Fahrzeugantriebes und die verzögernden Kräfte der Fahrwiderstände und Bremsen beeinflusst. Der Reifen-Straße-Kontakt bestimmt das Kraftpotential, welches zur Beschleunigung, Verzögerung⁴ und Querführung des Fahrzeugs genutzt wird. In Fahrzeugquerrichtung wird von der sogenannten Quer- oder Lateraldynamik gesprochen. Diese beschreibt die Bewegung entlang des weiteren Bewegungsfreiheitsgrades des Fahrzeugs in der horizontalen Ebene. Sie beeinflusst maßgeblich das Spurhalten oder auch das Lenkverhalten des Fahrzeugs. Die Querdynamik wird hauptsächlich durch das Zusammenspiel der Fahrwerkkomponenten wie Reifen, Federung, Dämpfung sowie der Lenkung und Lenkerkinematik beeinflusst. Die Vertikaldynamik beschreibt die Bewegung in Richtung der Hochachse. Sie steht im Zentrum der Untersuchungen zum Feder-Dämpferverhalten und damit oft auch von Komfortuntersuchungen. Neben den translatorischen Freiheitsgraden gibt es die drei Rotationen um die beschriebenen Achsen. Diese werden als Nicken, Wanken und Gieren bezeichnet. (HEISSING et al., 2011; MITSCHKE, WALLENTOWITZ, 2004)

2.2.2 Anwendungsfelder von Fahrdynamikmodellen

Das wissenschaftliche und industrielle Interesse an der Modellbildung von Fahrdynamikmodellen ist groß. Modelle bieten vielseitigen Nutzen für Unternehmen und Forschungseinrichtungen. Einige Gründe nennen SCHRAMM, HILLER et al. (2018, S. 1-2):

- Fahrzeugmodelle können als Grundlage für die Auslegung und Entwicklung von Fahrzeugsystemen und -komponenten genutzt werden. Der Entwicklungszyklus lässt sich durch den Einsatz von Simulationen und virtuellen Prototypen verkürzen.
- Automobile Systeme werden immer komplexer und so auch deren Erprobungsbedingungen. Die virtuelle Erprobung kann dabei helfen, die Entwicklungskosten zu senken.
- Simulationen lassen sich beliebig oft wiederholen. So können Fahrmanöver in Simulationen unter definierten Randbedingungen reproduziert und besonders kritische Fahrmanöver gefahrlos durchgeführt werden.

Eine beispielhafte Auswahl für die Anwendung von Modellen in der Forschung am Lehrstuhl für Mechatronik der Universität Duisburg-Essen wird im Folgenden gegeben. Weitere Anwendungen im Bereich der Identifikation der Fahrdynamik werden in Abschnitt 2.6 gegeben.

⁴Eine aktiv geregelte Fahrzeugaerodynamik kann zusätzlich zur Verzögerung beitragen.

Fahrsimulator

Für den Betrieb des Fahrsimulator wird ein Fahrzeugmodell benötigt. Die Modellierungsart und Komplexität dieses Modells wird in Abhängigkeit des Untersuchungsgegenstandes gewählt. In UNTERREINER (2014) werden verschiedene Fahrzeugmodelle und deren Einfluss auf das Fahrgefühl untersucht. In KRACHT (2020) wird eine Methode präsentiert, mit welcher die Elastokinematik von Radaufhängungen in Echtzeit simuliert werden kann. Auf diese Weise können hochgenaue Fahrzeugmodelle im Fahrsimulator genutzt werden.

Fahrdynamikregel- und Fahrerassistenzsysteme

Mit dem Ziel der Verbesserung der Fahrzeugsicherheit, des Fahrkomforts oder der Fahrdynamik werden neue Systeme entwickelt und simuliert. Im Bereich zukünftiger Fahrzeugregelsysteme existieren unterschiedliche Veröffentlichungen zum Nutzen der Modellbildung und zur Absicherung dieser Systeme. In BAHR et al. (2020) wird ein Fahrdynamikregelmodell basierend auf einem Künstlichen Neuronalen Netz entwickelt, das zur Regelung des Wankwinkel genutzt wird. Ein alternativer Ansatz zur Regelung des Wankwinkels wird in SIEBERG et al. (2019) vorgestellt. Neben der Reduzierung des Wankwinkels wird auch der Nickwinkel reduziert. Für die Regelung wird ein nichtlinearer modellbasierter prädiktiver Regler eingesetzt. Für den Aufbau des Regler wird sowohl die Wank- als auch die Nickdynamik des Fahrzeugs durch physikalische Modellgleichungen beschrieben.

Fahr-, Prüf- und Lastzyklen

Der gesellschaftliche und politische Diskurs zur Klimaverträglichkeit von Fahrzeugen heutiger und zukünftiger Generationen treibt die Erforschung von Fahr-, Prüf- und Lastzyklen an. Aktuelle Veröffentlichungen sind von BLUME, REICHERTS et al. (2018), DRIESCH et al. (2020), KOPPERS (2018), SCHÜLLER (2019) und TEWIELE (2020). In KOPPERS (2018) wird beispielsweise basierend auf Längsdynamikmodellen unterschiedlicher Antriebstypologien der Energieverbrauch für verschiedene Fahrer untersucht.

2.2.3 Fahrdynamikmodelle

Die Modellbildung und Simulation der Fahrdynamik von Kraftfahrzeugen ist ein gut erforschter Bereich mit einer umfangreichen Literaturbasis. In UNTERREINER (2014) wird die historische Entwicklung der Fahrzeugmodellbildung für die einzelnen Jahrzehnte und Modellklassen dargestellt. Die ersten theoretischen Untersuchungen zur Fahrdynamik stammen aus den 1940-er bis 1950-er Jahren. Eine bis heute bedeutende Arbeit der Fahrdynamik ist die von RIEKERT, SCHUNCK (1940). Diese legt die Grundlagen des bis heute oft zur Beschreibung der Querdynamik verwendeten linearen Einspurmodells. Das lineare Einspurmodell ist ein auf der theoretischen Modellbildung basierender Ansatz, mit dessen Hilfe die Querdynamik eines Fahrzeugs für einen breiten Dynamikbereich beschrieben werden kann. Das Modell verfügt über zwei Freiheitsgrade und eignet sich zur Beschreibung der Fahrzeugbewegung in der Ebene.

Neben dem Einspurmodell haben sich verschiedene Modelle als Standard durchgesetzt. Die Wahl des Modellierungsansatzes hängt maßgeblich von der Anwendung ab. In Tabelle 2.1 wird eine Übersicht über verschiedene Modelle gegeben und deren Anwendungsfelder. Die Einfachmodelle verfügen über wenige Freiheitsgrade und sind daher in der Anwendung limitiert. Die komplexeren Modelle, wie etwa ein Mehrkörpermodell mit räumlicher Radaufhängung oder ein Finite Elemente Modell, sind in der Anwendung deutlich vielseitiger, allerdings in der Modellbildung, Parametrierung und in der Berechnung deutlich aufwendiger.

Seit Anfang des 20. Jahrhunderts wurde die Entwicklung des Fahrzeugs und im Speziellen des Fahrwerks in vielerlei Hinsicht vorangetrieben, der grundlegende Aufbau des Fahrzeugs ist allerdings bis heute gleich geblieben (BRAESS, SEIFFERT, 2013). Dies hat zur Folge, dass große Teile der grundlegenden fahrdynamischen Zusammenhänge bis heute unverändert und sehr umfangreich in Grundlagenwerken beschrieben sind. Wissenschaftliche Arbeiten, welche die Grundlagen der theoretischen Modellbildung der Fahrzeugdynamik dokumentieren, sind u. a. MITSCHKE, WALLENTOWITZ (2004, erste Auflage 1972), ZOMOTOR (1991), GILLESPIE (1992), AMMON (2013, Reprint, ursprünglich aus 1997), WILLUMEIT (1998), HEISSING et al. (2011, erste Auflage 2007), ABE (2015, erste Auflage 2009), PACEJKA (2006), SCHRAMM, HILLER et al. (2018, erste Auflage 2010). Die

Tabelle 2.1: Übersicht von Fahrzeugmodellen aus UNTERREINER (2014, S. 5)

Modell		Freiheitsgrade	Bewegungsart			
Einfachmodelle	Viertelfahrzeug	2				
	lineares	2				
	Einspurmodell					
	einfaches Triebstrangmodell	1-2				
Einspurmodelle	nichtlineares	3-6	Ebene Translation (Fahrverhalten), Bahnradius, Gieren	Längsdynamik (Antreiben und Bremsen)	Wank- und Nickbewegung	Vertikaldynamik (Schwingungen)
	Einspurmodell					
	nl. ESM mit Wankmodell	4-7				
nl. ESM mit Nickmodell	4-7					
Zweispurmodelle	Fünf-Massen-Modell	14-15				
	Schräglenker-Modell	14-20				
Mehrkörpermodelle mit räumlicher Radaufhängung		≥ 15				
Finite Elemente Modelle		≥ 20				Komponentenbewegung

Arbeiten sind aufsteigend nach dem Erscheinungsjahr der Erstausgabe sortiert. Manche Arbeiten liegen in neueren Auflagen vor.

Bei den hier aufgelisteten Arbeiten handelt es sich um Veröffentlichungen, die die Fahrdynamik basierend auf physikalischen Zusammenhängen beschreiben. Die in den Arbeiten veröffentlichten Modelle zählen damit zu der Kategorie der theoretischen Modellbildung. Einige Systeme/Komponenten (bspw. Reifen) eines Fahrzeuges können mit physikalischen Zusammenhängen nur unter großem Aufwand oder unzureichend beschrieben werden. Die Übertragungseigenschaften dieser Komponenten sind hoch nichtlinear, sodass diese häufig über mathematische Modelle ohne physikalische Beschreibung abgebildet werden. Ein sehr bekanntes Modell aus dieser Modellkategorie ist das Magic Formula Reifenmodell von PACEJKA (2006). Bisher sind solche experimentellen Modellbildungsansätze in den Standardwerken zur Fahrdynamik selten. Ein Ansatz, der vermehrt in den Fokus rückt, sind Modelle basierend auf Künstlichen Neuronalen Netzen (Abk.: KNN, eine Übersicht über relevante Arbeiten wird in Abschnitt 2.6 gegeben). Dieser Modellierungsansatz profitiert von den in den letzten Jahren gestiegenen Rechenleistungen und Möglichkeiten große Datenmenge zu speichern und zu verarbeiten (CHOLLET, 2018). Die Modellierungsmöglichkeiten und Ansätze mit KNN sind sehr vielfältig, sodass in der Literatur keine Standardarchitekturen/-modelle für den jeweiligen Anwendungsfall gefunden werden konnten, die vergleichbar zu den Modellen aus Tabelle 2.1 sind.

2.2.4 Fahrversuch

Die Modellbildung kann gemäß der Beschreibung aus Abschnitt 2.1.1 in zwei Pfade, die theoretische und die experimentelle Modellbildung, aufgeteilt werden. Modelle, die ausschließlich mittels theoretischer Modellbildung erstellt werden, beziehen sowohl ihre Modellstruktur als auch die zugehörigen Parameter aus physikalischen Zusammenhängen. In der Fahrdynamik existiert eine umfassende Modellbasis (siehe 2.2.3), mit welcher die physikalischen Zusammenhänge für den jeweiligen Anwendungsfall hinreichend genau beschrieben werden können. Die Modellstruktur ist für Fahrzeuge mit etablierten Fahrwerks- und Antriebskomponenten vorhanden und kann mit kleineren Anpassungen übernommen werden. Die Parameter dieser Modelle wiederum müssen aus Systemwissen und physikalischen Zusammenhängen bestimmt oder durch Experimente identifiziert werden. Eine vollständige Parameterdefinition basierend auf physikalischem Wissen ist in der Regel nicht möglich, sodass unbekannte Parameter (bspw. Reifenparameter) durch Identifikationsmethoden bestimmt werden müssen (SCHRAMM, HILLER et al., 2018).

Die Identifikation erfordert experimentelle Untersuchungen der Fahrzeuge sowie der Fahrzeugkomponenten und kann eingeteilt werden in Untersuchungen an Prüfständen und bei realen Fahrversuchen. Für diese Arbeit wird der Fahrversuch genauer betrachtet. Das methodische Vorgehen für fahrdynamische Untersuchungen mittels Fahrversuchs ist in der ISO 15037-1 genormt. Für die Analyse der Fahrdynamik haben sich standardisierte Abläufe für den Fahrversuch etabliert. Die Auswahl eines oder mehrerer Fahrmanöver ist, genau wie die Auswahl der Messvariablen, abhängig vom Untersuchungsziel.

Gängige Fahrmanöver sind wiederum in eigenen Normen spezifiziert. Eine Übersicht zeigt Tabelle 2.2. In Abschnitt 2.1.2 werden die Ziele einer Identifikation und die Anforderungen an einen Versuch beschrieben. Für ein erfolgreiches Experiment muss die Dynamik des Systems in geeigneter Weise angeregt werden. Aus der aufgezeichneten Systemantwort können dann die notwendigen Informationen für die Modellbildung extrahiert werden. Entsprechend der Untersuchungsziele kann aus einem Katalog an Fahrmanövern gewählt und die Fahrzeugdynamik gezielt angeregt werden. Die Manöver können nach ZOMOTOR, BRAESS et al. (1997) und ZOMOTOR, BRAESS et al. (1998) entsprechend ihrer Bedeutung und Eigenschaften für die Identifikation in unterschiedliche fahrdynamische Domänen

Tabelle 2.2: Übersicht von nach ISO genormten Fahrmanövern für Pkw. Die Zuordnung der Manöver bezüglich der jeweiligen Verhalten geschieht in Anlehnung an ZOMOTOR, BRAESS et al. (1997) und ZOMOTOR, BRAESS et al. (1998). Fahrmanöver für weitere Fahrzeugklassen oder nicht genormte Manöver werden hier nicht aufgelistet.

	Norm	Manöverart	Manöverbeschreibung
Kurvenverhalten	ISO 4138	Open-Loop	Stationäre Kreisfahrt
	ISO 7975	Open-Loop	Bremsen während der Kreisfahrt
	ISO 9816	Open-Loop	Lastwechselreaktion bei Kreisfahrt
Wechselkurvenverhalten	ISO 13674-1	Open-Loop	Lenken um die Mittellage: Weave Test (Pendeln)
	ISO 13674-2	Open-Loop	Lenken um Mittellage: Transition Test (Frequenzgang/Wedeln)
	ISO 3888-2	Closed-Loop	Spurwechsel: Ausweichtest
Übergangsverhalten	ISO 3888-1	Closed-Loop	Doppelter Spurwechsel
	ISO 7401	Open-Loop	Transiente querdynamische Rückmeldung, Lenkwinkleingabe: <ul style="list-style-type: none"> • Lenkwinkelsprung • Einzelsinus • Dauersinus • Dreieckimpuls • Regellose Eingabe
Geradeausfahrtverhalten	ISO 17288-1	Open-Loop	Freies Lenkverhalten: freigegebene Lenkung
	ISO 17288-2	Open-Loop	Freies Lenkverhalten: Lenkimpuls
	ISO 14512-1	Open-Loop	Bremsen auf μ -Split
	ISO 12021	Open-Loop	Seitenwindempfindlichkeit
	ISO/TS 20119	Closed-Loop	Lenken um die Mittellage: Streuung bei Geradeausfahrt
	ISO 21994	Open-Loop	Bremsweg bei Geradeausfahrt mit ABS

eingeteilt werden. Für die Fahrmanöver wird unabhängig von der Fahrdomäne zwischen Open-Loop und Closed-Loop⁵ unterschieden.

2.3 Naturalistic Driving Study

Naturalistic Driving Studies⁶ (Abk.: NDS, dt.: *Naturalistische Fahrverhaltensbeobachtungen*, Übersetzung in Anlehnung an METZ et al. (2014)) sind ein junges Forschungsfeld, das seinen Ursprung in der Unfallforschung der 2000er-Jahre in den USA hat (DINGUS et al., 2006). Unter möglichst natürlichen und von der Studiensituation unbeeinflussten Fahrgegebenheiten wird das alltägliche Fahrverhalten der Probanden über einen längeren Zeitraum aufgezeichnet und ausgewertet. Naturalistic Driving Studies sind durch ihre langen Laufzeiten von mehreren Monaten bis zu Jahren sowie die große Menge an anfallenden Messdaten charakterisiert. Diese Eigenschaften machen NDS zu Profiteuren der technischen Entwicklung hinsichtlich der Datenerfassung und Speicherung großer Datenmengen.

Die erste groß angelegte NDS war die Anfang der Jahrtausendwende in den USA durchgeführte Studie „The 100-Car Naturalistic Driving Study“ von DINGUS et al. (2006). Die Studie wurde in Zusammenarbeit mit dem Transport Institute der Virginia Tech und der National Highway Traffic Safety Administration sowie weiterer Projektpartner durchgeführt. Der Studienfokus lag hierbei in der Untersuchung von Pre-Crash- und Beinahe-Crash-Szenarien. Diese sollten in natürlichen Verkehrssituationen aufgezeichnet und anschließend untersucht werden. Für die Studie wurden 100 Fahrzeuge mit einer eigens entwickelten Sensorplattform ausgestattet. Die Fahrer der Fahrzeuge hatten keine instruierten Fahraufgaben und nutzten die Fahrzeuge für alltägliche Fahrten. Die Fahrer sollten sich nach Möglichkeit nicht ständig bewusst sein, dass die Fahrt aufgezeichnet wird und sie Teil eines Experimentes sind. Zu der verbauten Messhardware zählten Kamera- und Radarsensoren sowie ein Logger zur Kommunikation mit dem Fahrzeugbus und den Beschleunigungssensoren. Die Hardwarekosten pro Fahrzeug beliefen sich auf mehrere tausend Dollar. (LEWIS et al., 2002)

2.3.1 Begriffserklärung Naturalistic Driving Study

Die Versuchsmethodik der Naturalistic Driving Study wird in wissenschaftlichen Veröffentlichungen sowie als Methode für Forschungsprojekte häufig genutzt. Der Begriff NDS wird dabei oft eigenständig definiert und beschrieben, ohne einer allgemeinen Definition

⁵*Open-Loop*: Fahren im offenen Regelkreis, Stellgrößen sind unabhängig vom Ergebnis der Fahrzeugreaktion. *Closed-Loop*: Fahren im geschlossenen Regelkreis, Informationen über die Fahrzeugreaktion werden zum Fahrer (oder Eingaberegler) zurückgeführt und mit der gewünschten Fahrzeugreaktion abgeglichen, ggf. werden die Stellgrößen entsprechend angepasst. (ISO 8855)

⁶Die Verwendung und Übersetzung des Begriffs Naturalistic Driving Studies ist in der deutschsprachigen Literatur nicht einheitlich. Diese Arbeit orientiert sich an dem Sprachgebrauch von LIETZ et al. (2011) und nutzt den Ausdruck als Fachterminus und in Englisch.

zu folgen. Dies hat zur Konsequenz, dass zwar ein allgemeines Verständnis dieses Begriffes existiert, allerdings mit Unterschieden im Detail. An dieser Stelle werden die wichtigsten Merkmale der unterschiedlichen Definitionsansätze zusammengetragen.

In der Literatur finden sich unterschiedliche Definitionen, die sich allerdings in den wesentlichen Punkten gleichen. In DINGUS et al. (2006) wurde der Begriff *Naturalistic* als „Unauffällige Beobachtung; Beobachtung des Verhaltens, das sich in seiner natürlichen Umgebung abspielt“⁷ definiert. In den Folgejahren wurde das Verständnis zu NDS geschärft. In einer Veröffentlichung von BACKER-GRØNDAHL et al. (2009) im Rahmen des Forschungsprojektes PROLOGUE heißt es: “[...] zur naturalistischen Fahrbeobachtung gehört die unaufdringliche Beobachtung normaler Fahrer in ihrem normalen Fahrkontext während der Fahrt mit ihren eigenen Fahrzeugen.“⁸ PROLOGUE war ein Forschungsprojekt, welches von der Europäischen Union gefördert wurde, und die Möglichkeiten, den Nutzen und die Herausforderungen einer NDS in Europa untersucht hat. Der Abschlussbericht liefert eine Definition: „Eine Studie, die durchgeführt wurde, um einen Einblick in das Fahrerverhalten während der täglichen Fahrten zu erhalten, indem Einzelheiten über den Fahrer, das Fahrzeug und die Umgebung mithilfe von unauffälligen Datenerfassungsgeräten und ohne experimentelle Kontrolle aufgezeichnet wurden.“⁹ NDS lassen sich ferner über ihre Merkmale charakterisieren. In VAN SCHAGEN, WELSH et al. (2011) werden neben einer Definition auch fünf Hauptmerkmale einer NDS genannt:

1. „Die Fahrzeugführer nutzen ihr eigenes Fahrzeug in der üblichen Weise.
2. Die gesammelten Daten erfassen den Fahrzeugführer, das Fahrzeug sowie das umgebende Verkehrsgeschehen.
3. Die Messsensorik ist unauffällig und der Fahrzeugführer ist sich dieser nach kurzer Zeit nicht mehr bewusst.
4. Im Fahrzeug befinden sich keine Beobachter des Versuchs.
5. Die Datenaufzeichnung erfolgt kontinuierlich während der Fahrt.“¹⁰

Ähnliche Merkmale nennen auch die Arbeiten von BÄRGMAN (2015), LIETZ et al. (2011) und CARSTEN et al. (2013). Letztere ergänzen, dass NDS über einen längeren Zeitraum

⁷DINGUS et al. (2006) Glossary of Terms: S. XX, Original: “Unobtrusive observation; observation of behavior taking place in its natural setting.“

⁸BACKER-GRØNDAHL et al. (2009) S. 9, Original: “[...]naturalistic driving observation includes unobtrusively observing normal drivers in their normal driving context while driving their own vehicles.“

⁹VAN SCHAGEN, WELSH et al. (2011) S. 11, Original: “A study undertaken to provide insight into driver behaviour during every day trips by recording details of the driver, the vehicle and the surroundings through unobtrusive data gathering equipment and without experimental control.“

¹⁰VAN SCHAGEN, WELSH et al. (2011) S. 11, Original: “Drivers use their own vehicles in their normal manner. The data gathered covers the driver, vehicle and surrounding road environment. The instrumentation is unobtrusive and drivers cease to be aware after a short period. There are no observers present in the vehicle. Data is recorded continuously during the driving process.“

angewandt werden sollen, sodass unterschiedliche Tages- und Nachtzeiten sowie Jahreszeiten erfasst werden. Die von VAN SCHAGEN, WELSH et al. (2011) genannten Merkmale sind allerdings nicht für jede Studie gültig, so werden beispielsweise in den Studien UDRIVE (2020) und China-FOT (*CTS-ChinaFOT* 2020) (siehe Tabelle 2.3) keine eigenen Fahrzeuge genutzt. Die Merkmale dienen vielmehr als Orientierung, lassen jedoch ohne Normung Spielraum für Abweichung.

Field Operational Tests¹¹ (Abk.: FOT, dt.: *Operative Feldversuche*) sind eine zu NDS ähnliche Methode, die sich in einigen Eigenschaften von NDS abgrenzt. In FOT werden unter realen Bedingungen im Vorfeld definierte Events untersucht, die allerdings nicht gezielt durch den Versuchsaufbau oder von Außen getriggert werden. Im Anschluss an die FOT werden diese Events in den aufgezeichneten Daten identifiziert und extrahiert. FOT dienen als Evaluierungsmethode für Fahrerassistenzsysteme und -funktionen mit dem Ziel, die Vorteile dieser Systeme im natürlichen Verkehr und unter realen Bedingungen nachzuweisen. Methodenbedingt unterscheiden sich FOT und NDS im Grad der Versuchskontrolle (siehe Abbildung 2.5), wobei NDS explorativer als FOT sind (FOT-NET, CARTRE, 2018).

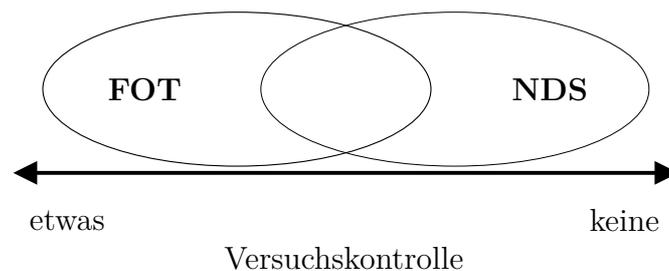


Abbildung 2.5: Grad der Versuchskontrolle von NDS und FOT aus FOT-NET, CARTRE (2018)

2.3.2 Forschungsschwerpunkte von Naturalistic Driving Studies

Die Forschungsschwerpunkte von NDS erstrecken sich über mehrere Themenfelder und ergeben sich aus den Charakteristiken der Studienart. In BACKER-GRØNDAHL et al. (2009) wird eine Literaturrecherche zu groß angelegten NDS¹² durchgeführt. In der Arbeit werden die Untersuchungsschwerpunkte der durchgeführten Studien betrachtet und Schwerpunkte herausgearbeitet, mit dem Ergebnis, dass viele Studien das Fahrerverhalten untersuchen. Es wird zwischen den Themen der Ablenkung und Unaufmerksamkeit des Fahrers, Fahrspurwechsel-Verhalten sowie Fahrereigenschaften und -zuständen unterschieden. Ferner werden die Schwerpunkte Fahrzeugsysteme, Wechselwirkung von Fahrzeugklassen und dem Nutzen in Anwendungen wie der Fahrerschulung untersucht.

¹¹Fachterminus; wird in Englisch verwendet

¹²Es wurden ausschließlich Studien betrachtet, welche das Fahrerverhalten erfassen, im öffentlichen Straßenverkehr, ohne beobachtende Personen, mit kontinuierlicher Datenerfassung und teilweise in privaten Fahrzeugen durchgeführt wurden. FOTs wurden bei der Untersuchung ausgeschlossen.

Basierend auf der Analyse von BACKER-GRØNDAHL et al. (2009) und weiteren Expertenmeinungen haben VAN SCHAGEN, DE CRAEN et al. (2010) eine Befragung unter 137 Experten¹³ (größtenteils aus Europa, u. a. Regierungs-, Industrie- und Forschungsvertreter) durchgeführt. Es wurde untersucht, welche Themenfelder für groß angelegte NDS als besonders wichtig und als wertvoll zu untersuchen eingeschätzt werden. Es standen 17 Themen zur Auswahl. Die als am wichtigsten genannten Themen sind das Risikoverhalten, insbesondere Geschwindigkeitsüberschreitungen, dichtes Verfolgen und Fahren unter Alkoholeinfluss, das Verhalten vor einem Unfall, das Verhalten zur Unfallvermeidung und der Zustand des Fahrers, insbesondere Müdigkeit und verschiedene gesundheitliche Zustände. In dieser Auflistung zeigt sich erneut das große Interesse an der Erforschung des Fahrerverhaltens.

2.3.3 Beispiele für Naturalistic Driving Studies

Forschungsaktivitäten im Bereich NDS sind weltweit zu beobachten. In Tabelle 2.3 wird ein Überblick staatlich geförderter NDS der vergangenen Jahre in unterschiedlichen Regionen der Welt gegeben. Es werden ausschließlich Studien betrachtet, die öffentlich gefördert sind. Weiter werden lediglich Studien herangezogen, welche schwerpunktmäßig Pkw nutzen. Die Liste zeigt eine Auswahl groß angelegter und staatlich geförderter NDS. Auf rein industriell durchgeführte Studien wird bei dieser Auflistung verzichtet, da deren Ergebnisse häufig nur auszugsweise einsehbar sind.

Die Einträge zur Motivation aus Tabelle 2.3 dokumentieren die starke Fokussierung der Studien auf den Fahrer und dessen Verhalten. Der betriebene Aufwand zur Erzeugung der Studiendaten ist groß. So liegt der involvierte Personenkreis oberhalb 100 Probanden und Fahrzeugen. Die aufgezeichnete Fahrstrecke liegt zwischen 80 bis 5.700 Personenkilometern an Fahrstrecke, gemessen an der Fahrstrecke eines durchschnittlichen deutschen Fahrers im Jahre 2018. Das benötigte Budget für eine Studie liegt bei mehreren Millionen Euro bzw. US-Dollar. Die Projektpartner der Studien setzen sich in der Regel aus Vertretern der Wissenschaft und Industrie zusammen. Die verbauten Messplattformen sind teilweise über mehrere Jahre und Modellgenerationen entwickelt worden und kamen in unterschiedlichen Studien zum Einsatz.

¹³Anmerkung der Autoren der Studie VAN NES et al. (2010): Aufgrund der kleinen Sample-Größe kann die Studie nicht als repräsentativ für die europäische Bevölkerung gesehen werden.

Projektname	Herausgeber/ Projektpartner	Land/ Region	Zeitraum	Budget in Mill.	Versuchsträger	Strecke in Mill.	Motivation
100– <i>Car Naturalistic Driving Study</i> ^a	Virginia Tech, Nat. Highway Traffic Safety Adm.	USA	2001 bis 2006	-	über 100 Kfz Messplattform u. a. Video- kamera, Umfelderkennung	2 mi	Untersuchung von Pre-Crash- und Beinahe-Crash- Ereignissen
<i>Strategic Highway Research Program</i> ^b (SHRP2)	Virginia Tech, Nat. Highway Traffic Safety Adm. u. v. a.	USA	2006 bis 2015	232 \$ (nicht nur NDS)	über 3000 Kfz Messplattform u. a. Video- kamera, Umfelderkennung	49,7 mi	Verbesserung der Verkehrssicherheit, Untersuchung des Fahrerverhaltens
<i>Canada NDS</i> ^c (zgh. zu SHRP2)	University of Saskatchewan, Virginia Tech, u. v. a.	Kanada	2007 bis 2015	-	125 Kfz Messplattform u. a. Video- kamera, Umfelderkennung	0,7 mi	Untersuchung des Fahrerverhaltens bei Unfällen
<i>Australian NDS</i> ^d (ANDS)	University of Sydney, Monash University, u. v. a.	Austra- lien	2015 bis 2018	4 \$	346 Kfz Messplattform u. a. Video- kamera, Umfelderkennung	2 mi	Untersuchung der Tätigkeiten des Fahrers in un-/krit- ischen Situationen
<i>UDRIVE</i> ^e	SWOV Institute for Road Safety Research u. v. a.	Europa	2012 bis 2017	10,3 €	200 Kfz Messplattform u. a. Video- kamera, Umfelderkennung	2,3 km	Untersuchung des realen Verhaltens von Verkehrsteil- nehmern

Tabelle 2.3: Beispiele für groß angelegte weltweite Forschungsaktivitäten im Bereich NDS. Aufgeführt sind ausschließlich öffentlich geförderte Studien.

^a (LEWIS et al., 2002; DINGUS et al., 2006; KLAUER et al., 2006), ^b(STRATEGIC HIGHWAY RESEARCH PROGRAM 2 (SHRP 2), 2015)(MALFABON et al., 2014), ^c(VIRGINIA TECH TRANSPORTATION INSTITUTE, 2020; HANKEY, 2014), ^d(UNSW SYDNEY, 2020; REGAN et al., 2013; YOUNG et al., 2019), ^e(UDRIVE, 2020; BÄRGMAN et al., 2017; BARNARD et al., 2016)

2.4 Grundlagen zu Messgrößenerfassung und Buskommunikation

Heutige Fahrzeuge sind mit verschiedenen Sensoren ausgestattet, mit denen sie Messgrößen erfassen können. Für diese Arbeit werden Sensorsignale für die Identifikation von Fahrdynamikmodellen genutzt. Um den Ursprung der aufgezeichneten Signale (maximale Sampling Rate, Quantisierungs-/Messfehler) besser zu verstehen, werden relevante Verarbeitungsschritte von der Messgrößenerfassung bis zur Verarbeitung im Folgenden vorgestellt.

2.4.1 Messtechnikgrundlagen

Ein Signal ist eine Sequenz von Daten (natürlich oder synthetisch), welches als eine Funktion $s(t)$ der Zeit beschrieben werden kann. Diese können unterschiedliche Charakteristika (bspw. analog, diskret oder digital) besitzen (O'SHEA et al., 2011, S. 5).

Messkette

Physikalische Messgrößen werden von den Messaufnehmern des Fahrzeugs, den Sensoren, erfasst und zu Signalen verarbeitet. Die Verarbeitungsschritte, beginnend bei der Aufnahme der Messgröße bis zum verarbeiteten digitalen Messergebnis, werden in einer Messkette in Abbildung 2.6 visualisiert. Die Messkette besteht aus vier Messgliedern. Der Messaufnehmer erfasst die physikalische Messgröße und verarbeitet diese zu einem elektrischen Signal, dem Sensorausgangssignal. Das elektrische Signal ist analog und somit wert- und zeitkontinuierlich. Dieses wird normiert und für die Analog-Digital-Wandlung

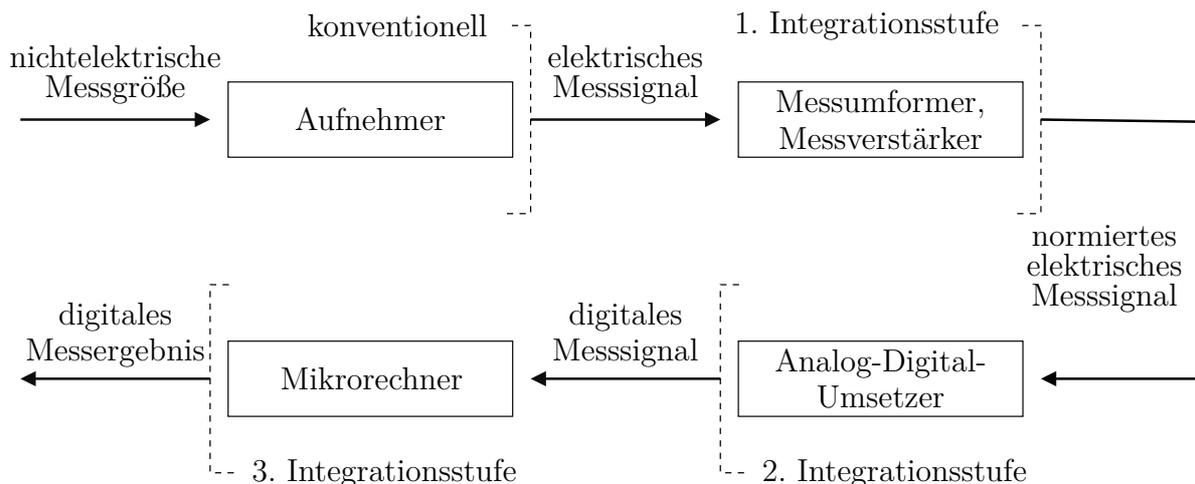


Abbildung 2.6: Komponenten einer Messkette aus DIN 1319-1 (S. 31). Die Abbildung ist in Anlehnung an REIF (2016, S. 112) um die Integrationsstufen eines Sensors ergänzt (gestrichelte Linien).

(Abk.: A/D-Wandlung) vorbereitet. Im Analog-Digital-Umsetzer wird das analoge Messsignal zunächst in ein diskretes und anschließend in ein digitales Messsignal gewandelt. Die Eigenschaften des digitalen Signals sind wert- und zeitdiskret. Das digitale Messsignal wird an einen Mikrorechner weitergegeben, der das digitale Messergebnis einem Empfänger zur Verfügung stellt. Das digitale Messergebnis ist ein aus Messungen gewonnener Schätzwert für den wahren Wert der Messgröße. (DIN 1319-1)

Die Messglieder einer Messkette werden vermehrt zu einer einzelnen Einheit in einem Sensor integriert. Die Integration wird in unterschiedliche Integrationsstufen unterteilt. Diese sind entsprechend dem Maß der Integration und der damit verbundenen Signalverarbeitung gegliedert. Die einzelnen Stufen, angefangen mit konventionellen Sensoren ohne Signalverarbeitung bis zur Integrationsstufe 3 mit busfähigen Sensoren, sind in Abbildung 2.6 dargestellt. (REIF, 2016, S. 22)

Abtasttheorem

Digitale Signalverarbeitung basiert auf der Transformation eines zeitkontinuierlichen Signals in eine Menge diskreter, abgetasteter Werte. Die Transformation erfolgt durch einen A/D-Wandler. Bei der Abtastung eines zeitkontinuierlichen Signals $s(t)$ werden die Signalwerte $s(t_n)$ zu diskreten Zeitpunkten t_n bestimmt. Für eine äquidistante oder gleichförmige Abtastung wird der Abtastensatz $\{t_{n,\text{uni}}\}$ aus $t_{n,\text{uni}} = nT, n \in \mathbb{Z}$ zusammengesetzt. Das Abtastintervall hat die Größe der Zeitkonstante T . (MERTINS, 2020)

Für eine verlustfreie Umwandlung des zeitkontinuierlichen Signals $s(t)$ in ein diskretes Signal $s(t_n)$, sodass eine anschließende Rekonstruktion des zeitkontinuierlichen Signals aus seinen Abtastwerten fehlerfrei möglich ist, muss das sogenannte Abtasttheorem nach Nyquist-Shannon erfüllt sein. Dieses besagt, dass ein Signal $s(t)$ aus seinen Abtastwerten $s(t_n | t_n \in \{t_{n,\text{uni}}\})$ eindeutig rekonstruiert werden kann, wenn die höchste Frequenz (Grenzfrequenz) ω_g von $s(t)$ kleiner als die halbe Abtastfrequenz $\omega_a = \frac{2\pi}{T}$ ist. Es gilt $\omega_g \leq \frac{1}{2}\omega_a$. Für das Signalspektrum $X(\omega)$ muss gelten, dass $X(\omega) = 0$ für $|\omega| \geq \omega_g$ gilt. Die Herleitung des Theorems kann MERTINS (2020, S. 97-99) entnommen werden.

Wird die nach dem Abtasttheorem gegebene minimale Abtastrate nicht eingehalten, so kann $s(t)$ nicht mehr fehlerfrei aus $s(t_n | t_n \in \{t_{n,\text{uni}}\})$ rekonstruiert werden. Es entstehen künstliche Artefakte im digitalen Signal, die als Aliasing bezeichnet werden (MERTINS, 2020).

Für sensorisch erfasste physikalische Messgrößen hängt die Bandbegrenzung des elektrischen Messsignals wiederum von der Dynamik des beobachteten oder gemessenen Systems ab. Unter der Annahme, dass der Messaufnehmer die Dynamik des Systems vollständig erfasst, ist das Signalspektrum $X(\omega)$ von dem Systemspektrum abhängig und folglich auch die maximale Signalfrequenz von der maximalen Systemfrequenz. Ist die maximale Systemfrequenz unbekannt, kann zur Begrenzung der maximalen Signalfrequenz ein Tiefpassfilter vor der Abtastung eingesetzt werden, um die Bandbegrenzung des Signals sicherzustellen.

Das Abtasttheorem für nicht gleichförmig abgetastete Signale ist in angepasster Formulierung des Kriteriums gültig. Wenn die durchschnittliche Abtastrate $\bar{\omega}_a$ größer als die zweifache Grenzfrequenz ω_g ist, gibt es ungeachtet des Stichprobensatzes $\{t_n\}$ immer eine eindeutige Lösung (MARVASTI, 2001, S. 170).

2.4.2 Bussysteme im Fahrzeug

Der Daten- und Informationsfluss im Automobil ist in Datennetzwerken, den sogenannten Bussystemen, organisiert. Busteilnehmern können über den Bus kommunizieren. Die Kommunikationsregeln werden über busspezifische Protokolle definiert. In Abbildung 2.7 ist eine schematische Busarchitektur für ein Fahrzeug dargestellt. Die einzelnen Busteilnehmer verfügen über ein Steuergerät (engl.: *Electronic Control Unit*, Abk.: ECU), welches die Kommunikation mit dem Bus ermöglicht. Die ECU kann hierbei auch ein sehr einfacher CAN-Baustein sein, der lediglich die Kommunikation via CAN-Bus ermöglicht, ohne über umfangreiche Funktionen zu verfügen. Für die Kopplung mehrerer Bussysteme können u. a. Gateways genutzt werden. Diese koppeln mehrere Netze für unterschiedliche Protokolle oder auch Busse mit unterschiedlichen Adressbereichen und Bitraten. Ausführliche Informationen zu Busarchitekturen kann ZIMMERMANN, SCHMID-

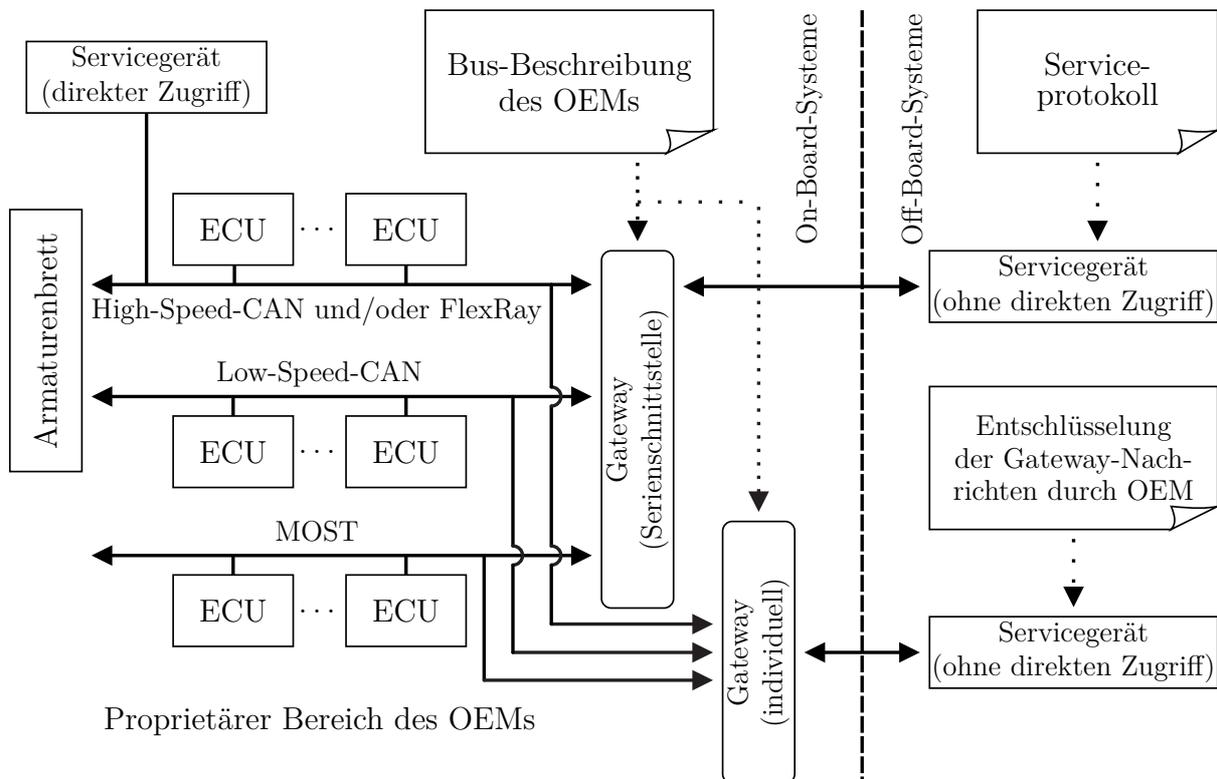


Abbildung 2.7: Bussysteme eines modernen Fahrzeugs mit möglichem Buszugriff mittels Diagnosegerät in Anlehnung an ZIMMERMANN, SCHMIDGALL (2014) und FOT-NET, CARTRE (2008)

GALL (2014) entnommen werden. Bei der Kommunikation wird zwischen On-Board- und Off-Board-Kommunikation unterschieden. Die On-Board-Kommunikation beschreibt die Kommunikation zwischen den einzelnen Fahrzeugsteuergeräten und lässt sich weiter in die einzelnen Busse unterteilen (siehe Abbildung 2.7). Als Off-Board-Kommunikation wird die Kommunikation zwischen dem Fahrzeug und externen Geräten bezeichnet. Ein wichtiger Bereich der Off-Board-Kommunikation ist die Kommunikation mit Diagnosegeräten sowie die Kommunikation über Modems (ZIMMERMANN, SCHMIDGALL, 2014). Eine Auswahl von Eigenschaften zu On- und Off-Board-Kommunikation sind in Tabelle 2.4 aufgelistet. Die On-Board-Kommunikation ist für den Datenzugriff die grundsätzlich bessere Wahl, da diese in allen Eigenschaften der Off-Board-Kommunikation überlegen oder zumindest ebenbürtig ist. Wie in Abbildung 2.7 dargestellt, ist die On-Board-Kommunikation ein proprietärer Bereich des OEMs und Eingriffe an diesen Systemen sollten, u. a. aus Sicherheitsgründen, nur durch den OEM selbst vorgenommen werden.

2.4.3 Buszugriff

Um Sensorsignale außerhalb des Fahrzeugbusses verfügbar zu machen, müssen diese vom Bus abgegriffen werden. Das Gerät, welches den Lese- und Schreibzugriff am Bus ermöglicht, wird im Folgenden als Diagnosegerät bezeichnet. Der Buszugriff kann auf unterschiedliche Arten realisiert werden. Drei Möglichkeiten werden hier diskutiert.

Direkter Buszugriff

In ROKICKI, SZCZUROWSKI (2015) wird ein Ansatz präsentiert, bei dem das Diagnosegerät als zusätzlicher Teilnehmer am Bus partizipiert. Hierfür wird die physikalische Verkabelung des Busses manipuliert und das Diagnosegerät als zusätzlicher Teilnehmer des zu beobachtenden Busses eingesetzt. Der gesamte Datenverkehr, der an diesem Bus anliegt, kann mit dieser Methode gelesen und aufgezeichnet werden. In Abbildung 2.7 ist dieser Ansatz in der linken oberen Ecke skizziert.

Tabelle 2.4: Anwendungsbereiche und Anforderungen an Bussysteme im Kfz aus ZIMMERMANN, SCHMIDGALL (2014, S. 3)

Anwendung	Botschaftsrate	Latenzzeiten	Fehlersicherheit
On-Board-Kommunikation			
High-Speed-Steuerung	Hoch	Sehr kurz	Extrem hoch
Low-Speed-Steuerung	Niedrig	Mäßig	Sehr hoch
Off-Board-Kommunikation			
Werkstattdiagnose	Niedrig	Unwichtig	Gering

Diagnose-Gateway

Eine Methode, die in den Arbeiten von CURRIE (2017) und HUYBRECHTS et al. (2018) genutzt wird, ist der Datenzugriff über das Diagnose-Gateway. Wie bereits in Abschnitt 2.4.2 beschrieben, verfügen Gateways über die Fähigkeiten, unterschiedliche Busse zu koppeln und deren Signale zu verarbeiten und weiterzuleiten. Der Zugriff auf das Diagnose-Gateway erfolgt über die standardisierte Diagnoseschnittstelle (engl.: *Data Link Connector*, Abk.: DLC, häufig als OBD2-Schnittstelle bezeichnet). Der Anschluss eines Lesegerätes über diese Schnittstelle ist einfach möglich und vollständig reversibel. Das Design des Diagnose-Gateways unterscheidet sich bei den einzelnen Herstellern, sodass nicht für alle Hersteller die gleichen Signale am Gateway verfügbar sind (ZIMMERMANN, SCHMIDGALL, 2014).

Individuelles Gateway

Eine hochentwickelte Lösung wird in FOT-NET, CARTRE (2008) vorgestellt. Bei dieser Studie mit Unterstützung eines OEMs wurde ein speziell für den Zweck der Studie spezifiziertes zusätzliches Gateway im Fahrzeug verbaut. Das Gateway extrahiert die für die Studie notwendigen Signale aus den einzelnen Bussen und stellt diese am Gateway zur Verfügung. Die auf diese Art zur Verfügung gestellten Daten können einfach empfangen und interpretiert werden, sodass der OEM keine Informationen zur Funktionalität des Busses an Dritte preisgeben muss.

2.4.4 CAN-Kommunikation

Die folgenden Beschreibungen beziehen sich auf den CAN-Bus, da dieser für die vorliegende Arbeit von besonderer Relevanz ist. Die CAN-Buskommunikation ist ereignisgesteuert. Buszugriff und Senderecht der Teilnehmer werden über eine Priorisierung der Nachrichten organisiert. Ein Sendebit wird gesetzt, wenn eine Nachricht von einem Sender auf den Bus geschrieben werden soll. Falls der Bus zu diesem Zeitpunkt nicht belegt ist, wird die Nachricht versandt. Ist der Bus zu diesem Zeitpunkt belegt oder eine andere Botschaft mit höherer Priorität soll gleichzeitig versandt werden, so wird das Versenden der Nachricht verzögert, bis der Bus frei wird. Das CAN-Protokoll garantiert keine inhärente Obergrenze für diese Wartezeit und gilt daher als nicht-deterministisch. Eine äquidistante Taktung des Messsignals bei der Übertragung von Signalen auf den Bus kann nicht garantiert werden. (ZIMMERMANN, SCHMIDGALL, 2014)

Neben dem Datenzugriff ist die Interpretation der CAN-Nachrichten zu realisieren. Die Syntax einer CAN-Nachricht kann in ZIMMERMANN, SCHMIDGALL (2014) nachgelesen werden. Die Semantik der Nachricht ist proprietäres Wissen der Hersteller. Um dennoch mit dem Fahrzeug kommunizieren zu können, können Diagnoseprotokolle genutzt werden. Diagnoseprotokolle kommunizieren entsprechend der Regeln des CAN-Protokolls, besitzen allerdings weitere Eingrenzungen bzgl. des Nachrichtenaufbaus und -inhaltes. Für CAN werden verschiedene Diagnosedienste unter dem Begriff DoCAN (*Diagnostic com-*

communication over Controller Area Network, ISO 15765-1) zusammengefasst. Hierzu zählen u. a. die Diagnosedienste wie OBD-II (ISO 15031-5) oder UDS (*Unified Diagnostic Service*, ISO 14229-1). Diagnoseprotokolle arbeiten häufig nach dem Frage-Antwort-Prinzip, sodass zuerst eine Diagnoseanfrage auf den Bus gesendet werden muss, um eine entsprechende Antwort zu empfangen. Die Anfrage wird an das Diagnose-Gateway gesendet und von dort auf den Bus weitergeleitet. Als Folge des Frage-Antwort-Prinzips können ausschließlich Messgrößen erfasst werden, welche für eine Anfrage vorgesehen sind. Dies sind nicht zwangsläufig alle Nachrichten, die auf dem CAN-Bus verfügbar sind. Für OBD-Dienste sind die Anfragen standardisiert und gesetzlich geregelt. Für alle Fahrzeuge, die den OBD-II Standard erfüllen, können identische Anfragen genutzt werden, die dann vom Gateway beantwortet werden. Die OBD-Signalliste ist auf Signale limitiert, die zur Emissionsprüfung befähigen und eignet sich daher nicht für die Fahrdynamikmessungen dieser Arbeit (ISO 15031-5).

In der vorliegenden Arbeit wird UDS verwendet, welcher in ISO 14229-1 definiert ist. Ebenda ist auch die allgemeine Syntax für Diagnoseanfragen und -antworten spezifiziert. Für UDS besteht herstellerspezifischer Freiraum für die Implementierung von Nachrichten (ZIMMERMANN, SCHMIDGALL, 2014). Für die meisten Fahrzeuge kann Diagnosesoftware erworben werden, welche die Kommunikation mit dem Fahrzeug über die entsprechenden Programme ermöglicht. Inwieweit eine solche Software für die Durchführung einer NDS geeignet ist, muss für die jeweilige Software und das Studiendesign im Einzelfall geprüft werden.

Eine Methode für ein individualisiertes Vorgehen, das eine erweiterte Kontrolle hinsichtlich der Abstraten, der Robustheit und der Automatisierbarkeit bietet, wird in REICHERTS, SCHRAMM (2020) beschrieben. Hierbei wird im Wesentlichen die Kommunikation kommerzieller Diagnosesoftware ausgewertet und emuliert. Schlussendlich können eigene Nachrichten in einer vorgegebenen Taktung gesendet und interpretiert werden.

Zur Kommunikation über das UDS-Protokoll sind drei Segmente einer UDS-Nachricht zu definieren. Diese sind ein Service Identifier, ein Parameter Identifier und der Inhalt der Nachricht. Das Wissen über diese Nachrichtensegmente liegt bei den Herstellern. In Tabelle 2.5 ist eine Diagnoseanfrage sowie die zugehörige Diagnoseantwort dargestellt. Eine UDS-Diagnoseanfrage beginnt mit dem Service Identifier (Abk.: SID) des Steuer-

Tabelle 2.5: Diagnosenachrichtenpaarung basierend auf dem UDS-Protokoll: Nachrichtenpaar aus Diagnoseanfrage und -antwort am Beispiel der Anfrage der Querbesehleuniung (PID= 2B0C_h) auf dem Steuergerät ABS (Anfrage SID= 760_h, Antwort SID= 768_h) für den Versuchsträger

	#	Datenfeld, Bytes 01 : 08 in hexadezimal							
SID	#	b ₁	b ₂	b ₃	b ₄	b ₅	b ₆	b ₇	b ₈
760 _h	#	03	22	2b	0c	--	--	--	--
768 _h	#	05	62	2b	0c	1e	7e	--	--

gerätes, an welches die Anfrage gesendet werden soll. Weiter muss in der Anfrage das angefragte Signal identifiziert werden. Dies geschieht über einen weiteren Identifier, dem sogenannten Parameter Identifier (Abk.: PID), welcher das Signal auf dem Steuergerät identifiziert (Byte 3-4). Mit der Paarung aus SID und PID ist ein Signal spezifiziert. Eine Diagnoseanfrage kann mit dieser Paarung und Kenntnis zum allgemeinen Aufbau einer UDS-Anfrage (siehe ISO 14229-1) gestellt werden. Der Inhalt der Diagnosenachricht muss in einem weiteren Schritt interpretiert werden. Hierfür sind in der Nachricht die Bytes hinter der PID reserviert. Für die Identifikation der unbekanntenen Nachrichtenteile wurde ein in REICHERTS, SCHRAMM (2020) präsentierter Ansatz genutzt.

2.5 Grundlagen der Statistik

Zur Analyse umfangreicher Datenmengen werden Methoden der Statistik angewandt. Die für diese Arbeit wesentlichen Grundlagen werden im Folgenden eingeführt.

2.5.1 Statistische Begriffe

Die Verwendung und Definition der statistischen Begriffe ist angelehnt an KOHN (2005, S. 8-12, 27–28, 36). Die Begriffe werden im Kontext der Anwendung dieser Arbeit eingeführt.

- **Statistische Einheit**

Die statistische Einheit ist eine einzelne Messgröße bzw. ein einzelnes Signal (beispielsweise die Geschwindigkeit v_x) und Träger von Informationen. Die Messgrößen sind zeit- und wertkontinuierliche Größen, die als Daten in diskreter Form vorliegen. Eine Datenmenge umfasst eine oder mehrere statistische Einheiten.

- **Merkmal, Merkmalsausprägung und -wert**

Die Eigenschaften der statistischen Einheit werden als Merkmale bezeichnet. Die möglichen Werte, die ein Merkmal einnehmen kann, heißen Merkmalsausprägungen. Merkmalsausprägungen, die während der Studie beobachtet (gemessen) werden, werden wiederum als Merkmalswert bezeichnet.

Informationen

Informationen werden zum Zweck der Problemlösung aus einer Datengrundlage gewonnen und leisten einen Beitrag zum Erkenntnisgewinn hinsichtlich einer These. Hierfür werden Daten verarbeitet, interpretiert und diesen wird eine Bedeutung zugeschrieben. Diese Beschreibung einer Information geschieht in Anlehnung an CHECKLAND, SCHOLLES (1990,

S. 300)¹⁴ und G. A. SILVER, M. SILVER (1989, S. 6)¹⁵ sowie BATESON (1973, S. 428)¹⁶. Das hier verwendete Konzept einer Information grenzt sich damit teilweise von der aus der Informationstheorie bekannten Definition von SHANNON (1948) ab.

2.5.2 Statistische Analysemethoden

Zur Analyse und Beschreibung einer Datenmenge können verschiedene Methoden verwendet werden.

Boxplot

Eine in dieser Arbeit häufig gewählte Darstellung einer Häufigkeitsverteilung ist der Boxplot. Hierbei werden die einzelnen Datenpunkte einer Stichprobe auf charakteristische Verteilungsmerkmale reduziert und in einer vorgegebenen Form dargestellt. Boxplots eignen sich zum Vergleich mehrerer Verteilungen. Ein Beispiel für eine Stichprobe und den zugehörigen Boxplot wird in Abbildung 2.8 gegeben. Auf der linken Seite sind die Datenpunkte der Stichprobe dargestellt und auf der rechten Seite der zugehörige Boxplot.

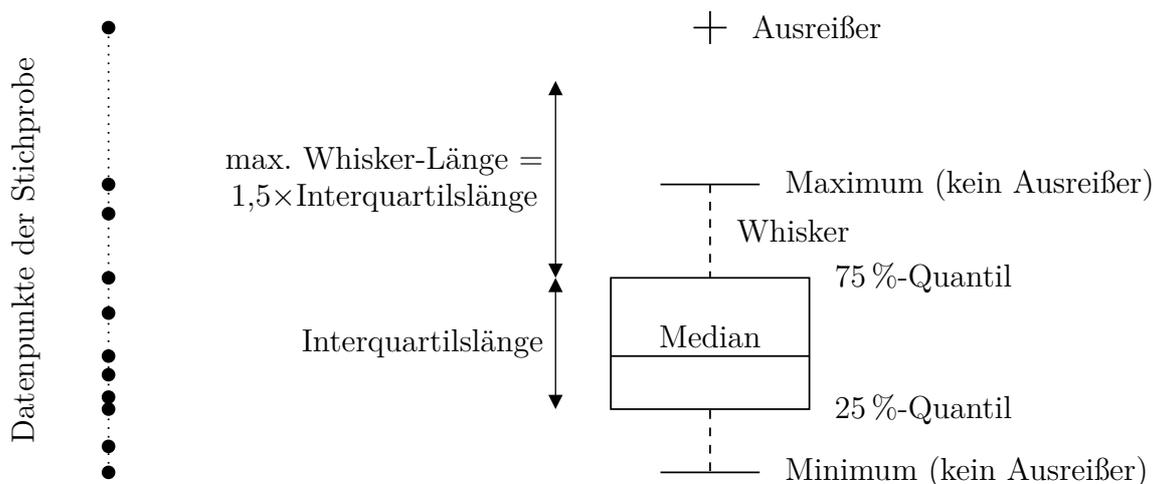


Abbildung 2.8: Aufbau eines Boxplots

Ein Boxplot besteht aus einer Box (Rechteck) und zwei Linien (Whisker). Die Whisker verlängern die Box und werden mit Querstrichen begrenzt. Die Höhe der Box wird durch das 25 %- bzw. 75 %-Quantil der Verteilung vorgegeben. Die Boxhöhe entspricht folglich

¹⁴CHECKLAND, SCHOLLES (1990, S. 300): “Information equals data plus meaning.“ zitiert nach FLORIDI (2005, S. 353)

¹⁵G. A. SILVER, M. SILVER (1989, S. 6): “Data is the raw material that is processed and refined to generate information.“ zitiert nach FLORIDI (2005, S. 353)

¹⁶BATESON (1973, S. 428): “In fact, what we mean by information-the elementary unit of information-is a difference which makes a difference.“ zitiert nach FLORIDI (2005, S. 358)

dem Bereich, in dem 50 % der Daten liegen. Die Breite der Box ist ohne Bedeutung. Die Linie innerhalb der Box ist der Median der Stichprobe. Die Whisker reichen vom Ende der Box bis zum am weitesten entfernten Datenpunkt der Verteilung, der innerhalb der Whisker-Länge liegt. Die maximale Whisker-Länge wird auf das 1,5-fache der Interquartilslänge, dem Abstand vom 25 %-Quantil bis zum 75 %-Quantil, vom unteren oder oberen Rand der Box definiert. Beobachtungen, die außerhalb der Whisker-Länge liegen, werden als Ausreißer mit einem Kreuz markiert. (KOHN, 2005, S. 49-50)

Kullback-Leibler-Divergenz

Eine NDS ist eine explorative Studie, bei der im Vorfeld nicht definiert wird, welche Ereignisse beobachtet werden sollen. Ohne eine solche Anforderung an die Studie ist die Definition eines Abbruchkriteriums, ein Kriterium zur Beendigung der Studie, nicht offensichtlich. Zwei Möglichkeiten zur Beendigung der Studie bieten sich an: Zum einen kann vorab eine ausreichend lange Studiendauer gewählt werden, bei der davon ausgegangen wird, dass diese eine Datenbasis erzeugt, die für die Untersuchungsziele ausreichend groß ist; zum anderen wird vor Beendigung abgewogen, wann der Datensatz voraussichtlich alle Informationen für die angeschlossene Analyse enthält unter Berücksichtigung der hohen Kosten und des Aufwands einer langen Laufzeit.

Für fahrdynamische Größen wird in WANG et al. (2017) ein statistischer Ansatz präsentiert, mit dem das Wachstum der Informationen eines Datensatzes über die Verteilung der Messgrößen ermittelt werden kann. In LIU, ZHU (2019) und LIU, ZHU et al. (2018) wird der statistische Ansatz aufgegriffen und weiterentwickelt. Die mathematischen Grundlagen dieser Methode werden im Folgenden vorgestellt.

Die zugrunde liegende Annahme des Ansatzes in WANG et al. (2017) ist, dass jede gemessene fahrdynamische Größe oder auch eine Kombination von Größen eine spezifische Verteilung besitzt, welche sich nach ausreichend vielen Beobachtungen bzw. Datenmesspunkten einstellt. Diese Verteilung wird durch Rahmenbedingungen des Versuchs definiert. Für eine NDS sind dies beispielsweise der Versuchsträger, der Verkehrsraum und die Fahrer. Die These aus WANG et al. (2017) wird durch die Arbeit von LIU, ZHU et al. (2018) gestützt. In dieser werden Beschleunigungsverteilungen unterschiedlicher Fahrer untersucht. Die einzelnen Verteilungen der Fahrer sind schon nach kurzer Zeit stationär und ändern sich nur noch minimal. Mit anwachsenden Messdauer und Messpunkten schwindet der Einfluss zukommender Messpunkte auf die Verteilung, sodass zwischen der Verteilung vor und nach Hinzufügen neuer Messpunkte nicht mehr unterschieden werden kann. Weitere Messungen haben keinen Einfluss auf die Verteilung.

Zur Quantifizierung der Ähnlichkeit zweier Wahrscheinlichkeitsverteilungen kann die Kullback-Leibler-Divergenz berechnet werden (KULLBACK, LEIBLER, 1951; KULLBACK, 1978). Diese gibt ein Maß für die Divergenz zwischen zwei Verteilungen und somit ein Maß für die Schwierigkeit, zwischen diesen zu unterscheiden. Diese Arbeit folgt der Definition der Kullback-Leibler-Divergenz (auch Kullback-Leibler-Information, Abk.: KLD, Formelzeichen D_{KL}) aus KONISHI, KITAGAWA (2008). Für die beiden Verteilungsdichte-

funktionen $g(x)$ und $f(x)$ mit $\{x_i\}_{i=1}^n$ einer Menge aus n unabhängigen Beobachtungen sei die Kullback-Leibler-Divergenz

$$D_{KL}(g; f) = \int_{-\infty}^{\infty} \log \left(\frac{g(x)}{f(x)} \right) g(x) dx. \quad (2.11)$$

Die KLD besitzt die Eigenschaften:

$$D_{KL}(g; f) \geq 0 \quad (2.12)$$

$$D_{KL}(g; f) = 0 \Leftrightarrow g(x) = f(x) \quad (2.13)$$

Basierend auf den beiden Eigenschaften kann die Annahme getroffen, dass die KLD kleiner wird, je näher sich die Verteilungsdichten $g(x)$ und $f(x)$ sind (KONISHI, KITAGAWA, 2008, S. 30). Bezogen auf zwei Stichprobenmengen $\{x_i\}_{i=1}^n$ und $\{x_i\}_{i=1}^{n+m}$ derselben Verteilung, kann für die zugehörigen Verteilungsdichtefunktionen $f_n(x)$ und $f_{n+m}(x)$ gefolgert werden, dass die Divergenzfolge

$$\lim_{n \rightarrow \infty} f_n(x) = \lim_{n+m \rightarrow \infty} f_{n+m}(x) = f(x) \quad (2.14)$$

ist und somit

$$\lim_{n \rightarrow \infty} D_{KL}(f_{n+m}; f_n) = 0 \quad (2.15)$$

gegen null konvergiert.

Übertragen auf eine NDS kann dieser Zusammenhang nicht einfach geschlussfolgert werden. Der Wahrscheinlichkeitsraum und die Merkmale einer NDS sind nicht unveränderlich. Bei gleichem Verkehrsraum, gleichen Fahrern und denselben Versuchsträgern wird sich bei wiederholter Messung eine Verteilung einstellen, die sich nur noch langsam ändert. Allerdings kann nicht mit Sicherheit gesagt werden, dass die Verteilung konvergiert und unveränderlich ist. Mit zunehmender Dauer wird die Änderungsgeschwindigkeit allerdings langsamer. Dies liegt an der Menge an hinzukommenden Messpunkten im Verhältnis zu der bestehenden Datenmenge. Neue Messpunkte fallen für die Verteilung weniger ins Gewicht:

$$0 < D_{KL}(f_{n+m}; f_n) \ll 1 \quad (2.16)$$

Gemäß der Definition aus LIU, ZHU et al. (2018) wurden in einer Studie ausreichend viele Messpunkte aufgezeichnet, wenn ein Γ existiert, sodass für alle n gilt

$$\forall \Gamma \leq n \leq N, D_{KL}(f_{n+m}(x); f_n(x)) < \xi. \quad (2.17)$$

Hierbei ist N die Anzahl aller Messpunkte der Studie und ξ ist eine positive reelle Zahl, die als Grenzwert dient.

Kerndichtenschätzer

Für eine geeignete Schätzung der Verteilungsdichten $f(x)$ basierend auf einer Menge von Beobachtungen $\{x_i\}_{i=1}^n$ können u. a. Kerndichtenschätzer (engl.: *Kernel Density Estimator*, Abk.: KDE) genutzt werden. Die für diese Arbeit relevanten Grundlagen werden dargestellt und die Herleitungen folgen der Definition von WAND, JONES (1995). Für weitergehende Einblicke sei auf SILVERMAN (1998) und WAND, JONES (1995) verwiesen. Die allgemeine Form eines d -dimensionalen Kerndichtenschätzers $\hat{f}(x; \mathbf{H})$ mit $\{x_i\}_{i=1}^n$ Beobachtungen ist

$$\hat{f}(x; \mathbf{H}) = n^{-1} \sum_{i=1}^n K_H(x - x_i). \quad (2.18)$$

Ein Kerndichteschätzer kann als Verfahren zur Schätzung der stetigen Wahrscheinlichkeitsverteilung einer Zufallsvariablen genutzt werden. Hierfür wird aus einer Menge von Beobachtungen $\{x_i\}_{i=1}^n$ mit Hilfe einer Kerndichtefunktion K_H eine Wahrscheinlichkeitsverteilung berechnet. Die Kerndichtefunktion setzt sich aus einem Kern K und einer Bandbreiten-Matrix \mathbf{H} bzw. einer Bandbreite w (1-dimensional) zusammen. Als Kern K kann aus verschiedenen Verteilungsfunktionen gewählt werden (bspw. Gauss-Kern mit einer Normalverteilung). Die Bandbreite wiederum streckt oder staucht die Verteilungsfunktion des Kerns. Allgemein ist die Kerndichtefunktion

$$K_H(x) = |\mathbf{H}|^{\frac{1}{2}} K(\mathbf{H}^{\frac{1}{2}} x). \quad (2.19)$$

\mathbf{H} ist eine symmetrische, positiv definite Matrix der Dimension $d \times d$ und kann so gewählt werden, dass

$$\mathbf{H} = \text{diag}(w_1^2, \dots, w_d^2) : w_1, \dots, w_d > 0 \quad (2.20)$$

mit: d = Dimension
 w = Bandbreite

gilt. Für die Fläche der Kerndichtefunktion K_H gilt, dass

$$\int K_H(x) dx = 1 \quad (2.21)$$

ist. Für jede einzelne Beobachtung x_i wird somit eine Verteilungsdichtefunktion $K_H(x - x_i)$ aufgestellt, die um den Beobachtungswert x_i verschoben ist. Die resultierende Wahrscheinlichkeitsverteilung des Kerndichteschätzers ist die Überlagerung bzw. Summe der einzelnen Verteilungsdichtefunktionen, geteilt durch die Anzahl der Beobachtungen n . Der Grad der Überlagerung einzelner Verteilungsdichtefunktionen kann über die Bandbreite w gesteuert werden (ein Beispiel wird in Anhang A.4.1 gegeben).

Gauss-Kern

Als Kern K wird in Anlehnung an WANG et al. (2017) ein Gauss-Kern gewählt, da sich dieser in einem vergleichbaren Anwendungsfall bewährt hat. Die d -variate Normalverteilung des Gauss-Kerns ist definiert als

$$K(x) = (2\pi)^{-\frac{d}{2}} \exp\left(-\frac{1}{2}x^T x\right). \quad (2.22)$$

In dieser Arbeit werden der univariate ($d = 1$) und der bivariate Fall ($d = 2$) betrachtet. Für den univariaten Fall ($d = 1$) wird $K_{H,\text{uni}}$ zu

$$K_{H,\text{uni}}(x) = (2\pi)^{-1} w \exp\left(-\frac{1}{2w}x^T x\right) \quad (2.23)$$

und für den bivariaten Fall ($d = 2$) ist

$$K_{H,\text{bi}}(x) = (2\pi)^{-1} |\mathbf{H}|^{\frac{1}{2}} \exp\left(-\frac{1}{2}x^T \mathbf{H}^{-1}x\right), \quad (2.24)$$

mit der Bandbreite w und der Bandbreitenmatrix \mathbf{H} .

Bandbreite

In JONES, J. MARRON et al. (1996) beschreiben die Autoren die Wichtigkeit einer geeigneten Wahl der Bandbreite w für die Schätzqualität von \hat{f} . Die Bandbreite hat direkten Einfluss auf den Grad der Glättung. Bei unzureichender Glättung ist die resultierende Dichte- oder Regressionsschätzung zu grob und enthält Störmerkmale. Bei einer übermäßigen Glättung gehen wichtige Merkmale der zugrunde liegenden Struktur verloren.

Wie SILVERMAN (1998) anmerkt, hängt die Wahl einer geeigneten Bandbreite jedoch von der unbekanntem Verteilung ab, welche geschätzt werden soll. Daher ist eine adäquate Auswahl der Bandbreite nicht trivial. Für bestimmte Anwendungen ist eine Berechnungsvorschrift zur Bestimmung der Bandbreite wünschenswert. Im Folgenden wird kurz auf wichtige Auswahlverfahren zur Bandbreite eingegangen. Eine sehr häufig verwendete Methoden zur Bestimmung einer geeigneten Bandbreite ist *Silverman's Rule of Thumb* (Abk.: ROT) (SILVERMAN, 1998):

$$w_{\text{ROT},i} = \left(\frac{1}{n} \cdot \frac{4}{d+2}\right)^{\frac{1}{d+4}} \sigma_i \quad (2.25)$$

mit: w_i = Bandbreite der i -Variable ($i = 1, \dots, d$)

d = Anzahl der Dimensionen

n = Anzahl an Datenpunkten

σ_i = Standardabweichung der i -ten Variable ($i = 1, \dots, d$)

Der Ansatz hängt von der Anzahl der Dimensionen, der Anzahl der Datenpunkte sowie der Standardabweichung der Daten der jeweiligen Dimension ab. Mit steigender Datenmenge wird die Bandbreite kleiner. Wie zuvor erwähnt, ist die Bestimmung einer geeigneten Bandbreite nicht trivial, sodass dieser sehr simple Ansatz aus Gleichung 2.25 nicht für jede Anwendung geeignet ist. In JONES, J. MARRON et al. (1996) werden verschiedene Ansätze verglichen und für *Silverman's Rule of Thumb* wird nachgewiesen, dass durch diese teilweise inakzeptabel große Bandbreiten gewählt werden, sodass wichtige Eigenschaften speziell für multimodale Verteilungen verloren gehen. Für die vorliegende Arbeit wird dennoch der Ansatz nach Silverman gemäß Gleichung 2.25 gewählt. Eine Diskussion, weshalb diese Wahl für den vorliegenden Datensatz zulässig ist, kann Anhang A.4.1 entnommen werden.

2.6 Relevante Forschungsarbeiten

Zur genaueren Betrachtung der Forschungsfrage dieser Arbeit werden im Folgenden relevante Veröffentlichungen zum Untersuchungsgegenstand dargestellt. Die Literatur ist so unterteilt, dass zu Beginn die Parameter- und Modellidentifikation basierend auf theoretischer und experimenteller Modellbildung dargestellt wird. Die Datenbasis stammt aus Fahrversuchen. In Abschnitt 2.6.2 werden Arbeiten vorgestellt, deren Datenerfassung einige Eigenschaften einer NDS erfüllt. Die Datenbasis dieser Arbeiten wird hier als naturalistisch-nahe Datenbasis bezeichnet.

2.6.1 Identifikation der Fahrdynamik am Fahrversuch

Der Identifikationsprozess wird in Abschnitt 2.2 dargestellt. Die Identifikation basierend auf Daten aus dem Fahrversuch wird umfassend diskutiert. Einige Beispiele aktueller Forschungsarbeiten aus diesem Themenfeld werden im Folgenden dargestellt.

Beiträge zur theoretischen Modellbildung

Viele Simulationsmodelle basieren auf theoretischer Modellbildung (siehe Abschnitt 2.2.3). Häufig werden für die Parametrierung der Modelle Fahrversuche vorgesehen.

RIEGL, GAULL (2018) beschreiben einen Modellierungsansatz für ein echtzeitfähiges, komplexes, nichtlineares Fahrdynamikmodell. Für eine mögliche Übertragbarkeit des theoretischen Ansatzes auf ein reales Fahrzeug müssen zunächst die Parameter in Fahrversuchen auf einer Teststrecke identifiziert werden.

In TEWIELE (2020) werden die Systemgleichungen der Längsdynamik eines Kfz theoretisch hergeleitet. Für die Parametrierung werden unterschiedliche Annahmen getroffen und weitere Parameter bei einem separaten Fahrversuch auf einem Testgelände identifiziert.

Die Veröffentlichungen von HALFMANN (2001), HALFMANN, HOLZMANN (2003), HOLZMANN (2001) und HOLZMANN et al. (1999) beschreiben eine Methode zur Erstellung und Bedatung adaptiver Modelle. Für die Parametrierung werden mehrere Fahrmanöver in Testfahrzeugen durchgeführt.

In GUTH et al. (2021) wird die automatisierte Identifikation eines Fahrzeugreglers für hochautomatisierte Prüfmanöverfahrten basierend auf Fahrversuchen vorgestellt. Hierbei handelt es sich um Manöverfahrten eines intelligenten Fahrzeugs mit aktuierten Eingängen ohne Fahrer auf einem Testgelände.

Beiträge zur experimentellen Modellbildung

Die Identifikation der Fahrzeugquerdynamik eines Black-Box-Modells, eines linearen parametervarianten Modells, wird in CERONE et al. (2011) vorgestellt. Das Fahrzeug wird für die Untersuchung mit zusätzlicher Messsensorik ausgestattet und die Daten werden während spezifischer Manöverfahrten aufgezeichnet.

Um die Dynamik von Fahrzeugen abzubilden, hat HARNACK et al. (2018)¹⁷ ein Künstliches Neuronales Netz basierend auf LSTM-Zellen¹⁸ realisiert. Die Datenbasis wird mit der Simulationssoftware ADAMS/Car erzeugt. Es werden Manöverfahrten als Fahrscenarien genutzt.

In MILANES et al. (2014) wird der Reglerentwurf eines *Cooperative Adaptive Cruise Control* untersucht. Hierfür wird die Übertragungsfunktion der Längsdynamik mittels Sprungfunktionen der Geschwindigkeit und fahrzeugeigenen Sensordaten identifiziert.

Für den Aufbau eines Rollwinkelschätzers basierend auf LSTM-Zellen¹⁸ nutzen BLUME, SIEBERG et al. (2019) eine umfangreiche Datenbasis, die aus etwa 4.000 Einzelmanöverfahrten besteht. Die Daten stammen aus der Simulationssoftware IPG CarMaker.

In GRÄBER et al. (2019) wird ein hybrider Schwimmwinkelschätzer vorgestellt. Die verwendete Datenbasis aus 16 Stunden Fahrzeit deckt einen großen Umfang an Fahrsituationen und Fahrzeugkonfigurationen ab. Um sicherzustellen, dass die Datengrundlage für die experimentelle Modellbildung ausreichend vielseitig ist, werden eine Reihe von Fahrmanövern und zusätzlich freie Fahrten aufgezeichnet.

Für die vorgestellten Veröffentlichungen der theoretischen und experimentellen Modellbildung werden die Daten gezielt entsprechend der Anforderungen der jeweiligen Identifikation erzeugt, sodass die Versuchskontrolle bei allen Veröffentlichungen als sehr groß bezeichnet werden kann.

¹⁷Die Arbeiten von HARNACK et al. (2018), HOHN (2021) und VOSS (2021) sind als Vorstudien zu dieser Arbeit entstanden.

¹⁸Die *Long Short-Term Memory* (Abk.: LSTM) ist eine Architektur rekurrenter Künstlicher Neuronaler Netze. Für weitere Ausführungen siehe Abschnitt 5.4.

Einige der vorgestellten Arbeiten zur experimentellen Modellbildung zeigen den Bedarf an sehr großen Datenbasen für Identifikationszwecke auf, der mit ausschließlich Manöverfahrten nicht oder nur durch den zusätzlichen Einsatz von Simulationen abgedeckt werden kann.

2.6.2 Identifikation der Fahrdynamik basierend auf naturalistisch-nahen Fahrdaten

Die Autoren einiger weniger Veröffentlichungen befassen sich mit der Modellbildung der Fahrdynamik basierend auf naturalistischen Fahrdaten oder Daten, die diesem Kriterium nah kommen.

Die Arbeit von HOHN (2021)¹⁷ nutzt Felddaten aus einer Simulatorstudie und modelliert basierend auf dieser Datengrundlage die Fahrdynamik mittels LSTM-Zellen¹⁸. Die Probanden der Studie waren angehalten sich möglichst natürlich im Verkehrsszenario zu verhalten, sodass der Datensatz dem einer naturalistischen Fahrstudie ähnlich ist. Die Datenbasis besteht aus 130 Stunden Fahrt.

In der Studie DREAMS4CARS (2017), die viele Eigenschaften einer NDS erfüllt, wurden zwei Fahrzeuge im öffentlichen Verkehr auf einer definierten Route in der Nähe von Turin, Italien, jeweils etwa 50 km gefahren. Über die verwendeten Sensoren und benutzte Messelektronik ist wenig bekannt. Als Signale liegen die Längsgeschwindigkeit, die Gaspedalstellung, die Bremspedalstellung, die Gangwahl, das Motormoment und die GPS-Koordinaten, alle bei einer Abtastrate von 20 Hz, vor. (JAMES, ANDERSON, 2018)

- JAMES, ANDERSON (2018) präsentiert einen experimentellen Modellbildungsansatz der Längsdynamik für den Einsatz in Echtzeitanwendungen.
- In DA LIO et al. (2020) werden Künstliche Neuronale Netze zur Modellbildung der Längsdynamik basierend auf Fahrdaten untersucht. Physikalisches Wissen aus der theoretischen Modellbildung fließt in die Auswahl der Modellarchitektur mit ein. Dies hat zur Folge, dass das Künstliche Neuronale Netz interpretierbarer und robuster wird. Die Ergebnisse der Untersuchung zeigen, dass die Netze mit einer durch die Physik beeinflussten Architektur bessere Ergebnisse liefern als ohne.
- JAMES, ANDERSON, DA LIO (2020) greifen die Ergebnisse aus JAMES, ANDERSON (2018) und DA LIO et al. (2020) auf und vergleichen theoretische und experimentelle Modelle miteinander.
- In VICENTE et al. (2020) wird das Potential datengetriebener linearer Modelle zur Simulation der Längsgeschwindigkeit und Querdynamik von Fahrzeugen mit Modellen der theoretischen Modellbildung untersucht. Die Ergebnisse zeigen, dass unter normalen Fahrbedingungen einfache experimentelle Modelle in der Lage sind, die Simulationsfähigkeiten von physikalisch abgeleiteten Modellen (theoretisches Modell)

zu erreichen oder zu übertreffen, und gleichzeitig wesentlich einfacher sind als ein nichtlineares physikalisches Modell.

Die Modelle zeigen gute Ergebnisse und bieten einen vielversprechenden Ansatz, wenngleich die aufgezeichnete Datenmenge mit einer Fahrstrecke von insgesamt 100 km, nicht groß ist und so eine Aussage zur Validität der Modelle für alltägliche Fahrereignisse nur eingeschränkt möglich ist. Die Versuchskontrolle dieser Studie ist deutlich kleiner als bei einem Fahrversuch, aber deutlich größer als bei NDS. JAMES, ANDERSON, DA LIO (2020) merken an, dass die üblichen Kriterien an die Systemidentifikation durch den Datensatz nicht erfüllt werden, da die Eingänge nicht vollständig angeregt werden und nur eine Teilanregung beobachtet wurde. Für die vorgestellte Anwendung wird argumentiert, dass dieser Umstand vernachlässigt werden kann. Eine Diskussion zu den Eigenschaften und Limitierungen von Fahrdaten aus alltäglichen Fahrten wird nicht geführt.

2.7 Bisheriger Stand der Forschung

Für die Analyse eines Fahrzeugs sind Daten in unterschiedlichster Form die Grundlage. Dabei werden verschiedene, auf den jeweiligen Zweck angepasste Methoden eingesetzt, um Daten zu sammeln und die benötigten Informationen aus diesen zu gewinnen. Unterschieden werden natürliche Anregungen, die im normalen Betrieb auftreten und solche, die gezielt durch klar beschriebene Versuchsabläufe definiert werden.

Arbeiten aus dem Bereich der Fahrzeugdynamik, die das Ziel haben, die Dynamik zu analysieren oder Modellbildung zu betreiben, greifen meist auf gezielte, vielfach erprobte Fahrversuche zurück. Im Vergleich zur Datenaufzeichnung im Normalbetrieb bietet dieses Vorgehen einige Vorteile (vgl. Abschnitt 2.2.4). Dies ist insbesondere bei der Parameteridentifikation theoretischer Modelle eine valide Vorgehensweise. Sollen experimentelle Modelle erstellt werden, so müssen die Standardversuche vielfach wiederholt und die gemessenen Daten ggf. durch weitere Normalfahrten ergänzt werden, um eine ausreichende Datengrundlage zu schaffen. Nur so kann gewährleistet werden, dass der gesamte Dynamikbereich, den das Modell abdecken soll, auch in den Daten vorhanden ist.

Durch die vielfältige Datenaufzeichnung in modernen Pkw haben sich in den letzten Fahrzeuggenerationen neue Möglichkeiten der Informationsgewinnung ergeben. Jedes moderne Fahrzeug ermittelt laufend fahrdynamische Größen sowie eine Vielzahl weiterer Datenpunkte. Diese werden zunehmend in NDS verwendet, um das Verhalten der Fahrer oder die Nutzung eines Fahrzeugs im Normalbetrieb zu analysieren. Hierbei ist besonders interessant, dass möglichst keine Versuchskontrolle stattfindet. Die Nutzung des Pkws ist also gänzlich natürlich und folgt keiner bestimmten Fragestellung. Versuche, die im Normalbetrieb ermittelten Messungen für die Identifikation fahrdynamischer Größen zu verwenden, oder mit ihrer Hilfe Modelle zu parametrieren, sind bislang nur aus vereinzelten Projekten bekannt. In ersten wissenschaftlichen Veröffentlichungen (siehe Abschnitt 2.6.2) wird der Nutzen von Fahrten im öffentlichen Verkehr für die Identifikation aufgezeigt. Die Fahrdaten werden jedoch unter stark regulierten Studienvorgaben erzeugt, wobei die Da-

tenmenge gleichzeitig gering ist. Diese Daten sind nur eingeschränkt mit den Daten einer NDS vergleichbar.

2.8 Wissenschaftlicher Beitrag

Die vorliegende Arbeit schließt die Lücke zwischen den Feldern der klassischen und vielfach erprobten Identifikation von Parametern oder Modellen zur Beschreibung der Fahrdynamik auf der einen und der Datenerhebung sowie -analyse während täglicher Normalfahrten auf der anderen Seite. Es wird das Potential aufgezeigt, das die Sensordaten aus täglichen Fahrten für die Analyse und Modellierung der Fahrzeugdynamik haben. Dabei wird insbesondere der Fragestellung nachgegangen, in welchem Rahmen sich die Daten, die bei der Normalfahrt aufgenommen werden, zur Beantwortung fahrdynamischer Problemstellungen eignen. Diese Arbeit verwendet dabei als erste eine länger angelegte NDS für die Modellierung der Fahrzeugdynamik und macht diesen gesamten Themenbereich damit bewertbar.

Hierfür muss der Prozess zur Identifikation von Fahrdynamikmodellen an die Besonderheiten von NDS angepasst werden. Zu beachten sind insbesondere die sehr langen Studiendauern, die damit einhergehenden sehr großen Datenmengen sowie die unklare Laufzeit der Studie. Diese Arbeit zeigt, wie die Datenaufzeichnung gelingen kann und welche Störgrößen dabei ggf. zu beachten sind. Eine Datenbasis, die die Normalfahrten über ein gesamtes Jahr beinhaltet, ist im Rahmen dieser Arbeit entstanden und wird für die weitere Analyse verwendet.

Besonderer Wert wird auf die Betrachtung der aus den Messungen extrahierten Informationen gelegt. Der Informationszugewinn hinsichtlich der betrachteten Querdynamik nimmt mit steigender Studiendauer ab und stagniert schließlich. Die Arbeit zeigt deutlich, dass dies zur Messung redundanter Daten führt. Dies kann als Abbruchkriterium für die Studie definiert werden und ist als Leitlinie für ähnliche Studien zu verwenden. Im Rahmen dieser Arbeit wird auf verschiedene Art analysiert, wann kein weiterer Informationszugewinn mehr zu erwarten ist. Hierbei kommt neben statistischen Größen insbesondere die Betrachtung physikalischer Grenzen eines Pkws zum Einsatz. Damit wird eingängig bewertbar gemacht, ob der gesamte erwartbare oder mögliche Bereich bereits in den Daten abgebildet ist. Gerade bei den vielfach verwendeten experimentellen Modellen ist ein solcher Schritt entscheidend. Neben einem Abbruchkriterium für NDS wird zudem die Güte der Modelle, die auf der Grundlage der erhobenen Daten erreichbar ist, diskutiert. Die Arbeit zeigt damit, welche Dynamikbereiche mit Daten aus alltäglichen Fahrten identifizierbar sind. Es wird außerdem gezeigt, wo die Grenzen dieser Methodik sind und die ermittelten Daten ggf. durch zusätzliche Testfahrten ergänzt werden müssten.

Für diese Bewertungen stellt die Arbeit neben einem theoretischen Einspurmodell Betrachtungen mit Künstlichen Neuronalen Netzen an. Damit wird gezeigt, welche Grenzen auch experimentelle Modelle auf der Grundlage von NDS haben. Durch die verschiedenen Betrachtungen und eingesetzten Methoden liefert diese Arbeit die Grundlage und eine

mögliche Leitlinie zur Verwendung von naturalistischen Fahrdaten für die Modellierung von Fahrzeugen, aber auch für den Einsatz in artverwandten Themen.

Naturalistic Driving Studies in der Fahrdynamik

Naturalistic Driving Studies werden bisher nicht für Fahrdynamikuntersuchungen eingesetzt. Für den Einsatz von NDS für Identifikationszwecke müssen einige Anpassungen an den bestehenden Methoden vorgenommen werden. In diesem Kapitel werden die Methoden der Fahrdynamikidentifikation und der Naturalistic Driving Studies zusammengebracht, sowie ein Kriterium eingeführt, das eine Aussage hinsichtlich einer geeigneten Studiendauer ermöglicht. Ferner wird das Design der Fahrstudie zum Erzeugen einer Datenbasis präsentiert.

3.1 Identifikationsprozess für eine Naturalistic Driving Study

Der Ablauf einer NDS und der Identifikationsprozess müssen hinsichtlich der neuen Fragestellung angepasst und aufeinander abgestimmt werden. Der Identifikationsprozess wird auf die geänderten Versuchsbedingungen angepasst und die Methode der NDS wird integriert.

3.1.1 Identifikationsprozess für die Anforderungen einer NDS

Der Identifikationsprozess nach SÖDERSTRÖM, STOICA (1989) besteht aus fünf aufeinanderfolgenden Prozessschritten (siehe Abschnitt 2.2). Im Identifikationsprozess nach SÖDERSTRÖM, STOICA (1989) kann im Anschluss an den letzten Prozessschritt der Validierung zu jedem beliebigen vorherigen Schritt zurückgekehrt oder der gesamte Prozess beendet werden (siehe Abbildung 2.2). Die Möglichkeit zu vorherigen Schritten zurückzukehren, verschafft dem Prozess Flexibilität und Kontrolle in der Ausführung. Erkennt-

nisgewinn und Wissenszuwachs, welche während der einzelnen Prozessschritte entstehen, können in den nächsten Identifikationsdurchlauf einfließen und das Identifikationsergebnis verbessern. Der Identifikationsablauf ist folglich iterativ.

Mehrfache Iterationsschleifen können jedoch nur sinnvoll durchlaufen werden, wenn zwei Eigenschaften erfüllt werden. Zum einen muss die Durchführung jedes einzelnen Schrittes mit einem vertretbaren Aufwand wiederholt werden können und zum anderen müssen die jeweiligen Schritte ausreichend kontrollierbar sein, sodass der Versuch gezielt angepasst werden kann. Für eine NDS treffen diese Eigenschaften auf den Prozessschritt der Versuchsdurchführung/Datenaufzeichnung nicht zu. Die Versuchsdurchführung und die Datenaufzeichnung geschehen einmalig und über einen längeren Zeitraum bei gleichzeitig minimaler Versuchskontrolle. Als Folge kann in dem für NDS angepassten Identifikationsprozess nicht sinnvoll zur Versuchsdurchführung/Datenaufzeichnung zurückgesprungen werden. Der Pfad zur Versuchsplanung ist gestrichelt dargestellt. Es kann nicht ausgeschlossen werden, dass der Versuch angepasst und erneut geplant werden muss. Dies sollte, wenn möglich, durch detaillierte und gründliche Planung oder durch eine oder mehrere Vorstudien vermieden werden.

Im Identifikationsprozess aus Abbildung 2.2 folgt auf die Versuchsdurchführung/Datenaufzeichnung die Auswahl der Modellstruktur. Für NDS ist das Datenvolumen, das während der Versuchsdurchführung aufgezeichnet wird, sehr groß. Es werden daher Prozessschritte zur Datenaufbereitung und Datenanalyse vorgesehen. Diese werden mit Datenbank/-analyse bezeichnet und zwischen den Prozessschritten Versuchsdurchführung/Datenaufzeichnung und dem Prozessschritt Auswahl der Modellstruktur hinzugefügt (siehe Abbildung 3.1, Anpassungen am bestehenden Identifikationsprozess wurden erstmals in REICHERTS, HESSE et al. (2021) veröffentlicht).

Der Identifikationsprozess nach SÖDERSTRÖM, STOICA (1989) ist streng sequentiell organisiert. Mit der Erweiterung für NDS wird der Ablauf angepasst. Die Prozessschritte Versuchsdurchführung/Datenaufzeichnung sowie Datenbank/-analyse werden dauerhaft mit Beginn des Versuchs ausgeführt und nicht unterbrochen. Erst mit Beendigung der NDS wird die Datenaufzeichnung abgeschlossen und die folgenden Prozessschritte abgearbeitet. Wie das Prozessdiagramm aus Abbildung 3.1 zeigt, wird der Identifikationsprozess beendet, wenn eines von drei Kriterien erfüllt ist:

- Das Ziel der Studie ist erreicht und es wurde ein valides Modell identifiziert. Die Validität des Modells ist ein aufgabenspezifisches Kriterium, das aus der beabsichtigten Anwendung abgeleitet werden muss.
- Die Daten sind adäquat, d. h., bei einer Fortsetzung können keine weiteren Informationen in Bezug auf die zugrunde liegende Aufgabe gewonnen werden.
- Die maximale NDS-Dauer ist erreicht. Diese maximale Dauer wird oft durch nicht-technische Restriktionen bestimmt (z. B. Budgetbeschränkungen oder Entwicklungszyklen).

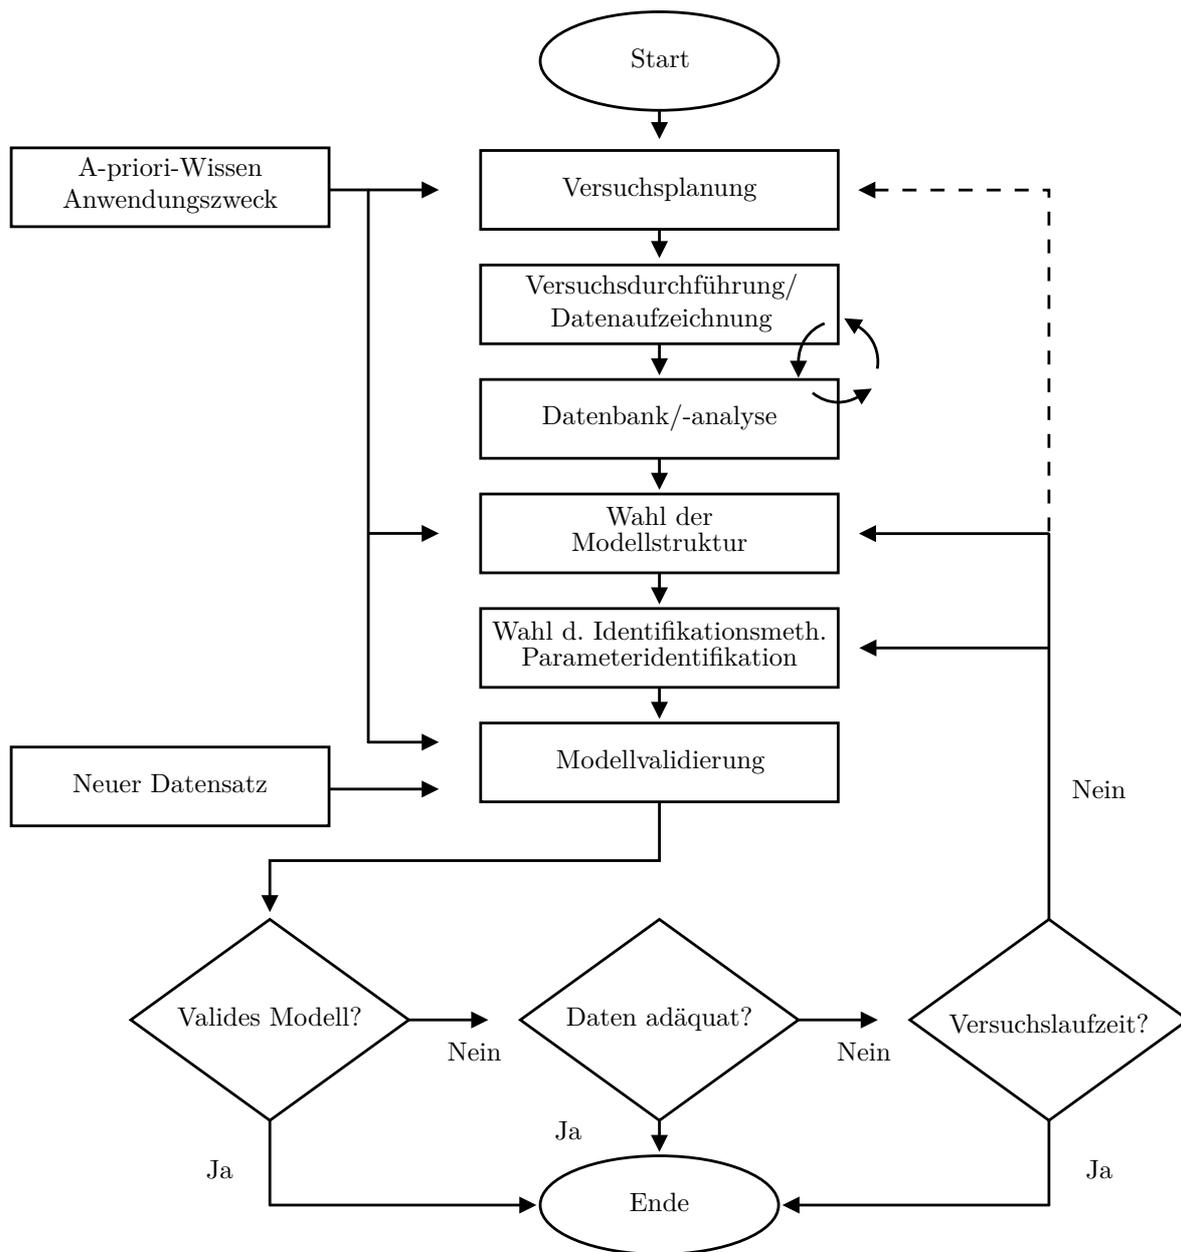


Abbildung 3.1: Ablauf einer Parameteridentifikation mit NDS in Anlehnung an SÖDERSTRÖM, STOICA (1989, S. 6). Abbildung erstmals präsentiert in REICHERTS, HESSE et al. (2021)

Der Erfolg der Identifikation hängt maßgeblich von den Informationen der Datenbasis ab. Ein Informationsmangel kann durch weiteren Informationszugewinn (aus weiteren Fahrten) behoben werden. In einer NDS kann der Informationszugewinn durch eine zukünftige Fahrt nicht aktiv beeinflusst oder exakt vorhergesagt werden. Eine Abschätzung, ob weitere Messungen zu weiteren Informationen führen, ist daher notwendig. Möglicherweise ist das Studiendesign und die resultierende Datenbasis für das Identifikationsvorhaben

ungeeignet. In diesem Fall kann der Prozess ohne valides Modell beendet werden. Der Prozess wird ferner beendet, wenn ein vorgegebener Zeitrahmen überschritten ist oder das Kriterium nach Adäquanz der Daten erfüllt ist.

3.1.2 Adäquanz der Studiendaten

Für die Identifikation eines validen Modells wird eine ausreichende Informationsmenge benötigt. Diese ist abhängig von der Anwendung und stammt größtenteils oder ausschließlich aus Versuchen. Für Versuche mit hoher Kontrolle (z. B. Fahrversuch) kann der Informationszugewinn gesteuert werden. Hierbei wird das zu identifizierende System gezielt angeregt und so die gesuchten Informationen erzeugt. Für NDS ist dies nicht möglich.

In WANG et al. (2017) wird die These formuliert, dass eine NDS zur Analyse von Fahrerverhalten nach einer bestimmten Studiendauer beendet werden kann, da keine oder kaum weitere Informationen aufgezeichnet werden. Gemäß der These von WANG et al. (2017) sind die Daten, die aufgezeichnet werden, maßgeblich vom Fahrerverhalten abhängig. Dieses sei wiederum zwar in hohem Maße von Unsicherheiten beeinflusst, etwa durch die Umgebung (z. B. andere Verkehrsteilnehmer) und den Fahrer selbst (z. B. durch seine Emotionen und mentalen Zustände), über einen längeren Studienzeitraum würden sich aber die statistischen Charakteristiken des Fahrerhaltens durchsetzen. Das Fahrerhalten folgt einem internen Modell und bei wiederkehrenden oder ähnlichen Situationen wird sich ein Fahrer entsprechend seines Fahrstils verhalten, sodass der Informationszugewinn für wiederkehrende Situationen begrenzt ist. Die Redundanz in den Daten wächst und es kommen keine weiteren Informationen hinzu. Für die Analyse der Fahrdaten einer NDS für fahrdynamische Untersuchungen muss hier zwischen zwei wesentlichen Aspekten unterschieden werden:

- Neben dem individuellen Fahrstil werden die beobachtbaren Messgrößen ganz maßgeblich über die Fahrphysik (etwa die maximale Geschwindigkeit des Versuchsträgers) limitiert. Diese überhaupt beobachtbaren fahrdynamischen Messgrößen werden im öffentlichen Verkehr durch die Verkehrsinfrastruktur und die Verkehrsregeln weiter eingeschränkt, sodass etwa gewisse Kombinationen von Fahrzeuggeschwindigkeit und Kurvenradius unter Einhaltung der Verkehrsregeln kaum möglich sind. So beschreibt RICE (1973), dass für Fahrten im öffentlichen Straßenverkehr die Beschleunigungswerte in bestimmten Grenzen liegen, die nur einen Bruchteil der physikalisch möglichen Grenzen ausmachen.
- Nachdem sich die aus physikalischen Überlegungen erwartbaren fahrdynamischen Beobachtungen eingrenzen lassen, wird diese Menge an Beobachtungen weiter durch fahrerindividuelles Verhalten (Fahrstil/-muster) eingeschränkt, sodass sich nach einer gewissen Studiendauer die statistischen Charakteristiken des Fahrerhaltens (feste Messgrößenverteilungen) einstellen und sich von diesem Zeitpunkt an Redundanzen in den Daten bilden (siehe WANG et al. (2017)). Auch für eine Gruppe von Fahrern ist davon auszugehen, dass diese Muster schnell zu beobachten sind und

die erwartbaren Messgrößen nach einer bestimmten Zeit Redundanzen aufweisen. So zeigen LIU, ZHU (2017), dass Verteilungen (etwa beim Beschleunigungsverhalten) für unterschiedliche Fahrer im öffentlichen Straßenverkehr sehr ähnlich sind.

Zusammenfassend kann somit für eine NDS unabhängig von der Probandenzahl konstatiert werden, dass sie unter fahrdynamischen Gesichtspunkten nach einer bestimmten Studiendauer beendet werden kann, da keine oder kaum weitere Informationen aufgezeichnet werden (REICHERTS, HESSE et al., 2021). Die vorliegende Datenmenge wird als adäquat bezeichnet. Der Begriff Adäquanz von Messdaten einer NDS wird wie folgt definiert:

Bei häufiger Wiederholung eines Versuchs nimmt der erwartete Informationszugewinn für weitere Versuchsdurchführungen ab. Die Adäquanz der Datenbasis wird erreicht, wenn weitere Versuche keinen oder einen nur sehr geringen Informationszugewinn für das geplante Identifikationsvorhaben leisten. Der Informationsgehalt einer adäquaten Datenmenge ist nicht zwangsläufig ausreichend für die Identifikation eines validen Modells. Damit beschreibt Adäquanz einen Datensatz, der jegliche im vorliegenden Versuchsaufbau messbare und für den Untersuchungsgegenstand relevante Information beinhaltet.

Die erreichbare Informationsmenge ist vorab nicht bekannt. Die Bewertung auf Adäquanz basiert daher auf verschiedenen Indizien. Für diese Arbeit wird physikalisches Systemverständnis mit statistischen Analysen kombiniert.

1. Messwertbereich

Fahrdynamische Messwerte sind häufig in ihrem Wertebereich begrenzt. Die Messwertbereiche sind teilweise durch physikalische Zusammenhänge beschreibbar (z. B. maximale Fahrzeuggeschwindigkeit). Eine Analyse über den in den Daten beobachteten Messwertbereich kann Aufschluss über eine adäquate Datenmenge geben.

2. Vergleich mit Beobachtungen anderer Studien

Aus den Beobachtungen anderer Studien können Rückschlüsse auf die eigenen Studiendaten gezogen werden, etwa im Hinblick auf Messwertverteilungen und die erwartbaren Messwerte.

3. Statistische Analyse der Messgrößen

Die Fahrdaten können mit statistischen Methoden (z. B. Kullback-Leibler-Divergenz) analysiert werden. Änderungen in der Messwertverteilung können Aufschluss über den Informationszuwachs der Daten geben. Hieraus kann geschlussfolgert werden, ob weitere Messungen sinnvoll sind.

In Abschnitt 2.3.1 werden die Unterschiede und die Abgrenzung von NDS zu FOT beschrieben. Der Identifikationsprozess aus Abbildung 3.1 ist ebenfalls für eine FOT anwendbar. Die Kriterien zur Bestimmung der Adäquanz werden sich bei dieser Art der Versuchsdurchführung ändern. Für eine FOT wird vorab festgelegt und definiert, welche Szenarien beobachtet werden. Folglich wird im Studiendesign bereits festgelegt, welche Informationen für die Identifikation benötigt werden und in welchen Fahrereignissen die benötigten

Informationen enthalten sind. Mit einer solchen Definition können die aufgezeichneten Fahrdaten untersucht und die entsprechenden Informationen extrahiert werden. Denkbare Fahrereignisse, die für eine Identifikationsaufgabe in realen Fahrten beobachtet werden sollen, sind beispielsweise Ereignisse, die Fahrmanövern aus Tabelle 2.2 ähnlich sind. Eine adäquate Datenmenge wäre erreicht, wenn die gesuchten Manöver in ausreichender Anzahl in den Daten vorhanden sind. Für eine solche Bewertung des Informationsinhalts der aufgezeichneten Datenmenge ist ein umfangreiches Systemwissen notwendig. In diesem Fall ist die Adäquanz sehr spezifisch für den bestimmten Anwendungsfall gegeben. Die benötigte Studienzeit ist tendenziell kürzer als bei einer NDS.

In dieser Arbeit wird der Ansatz einer NDS verfolgt. Ein Filtern der Daten hinsichtlich bestimmter Ereignisse, Merkmale oder Muster, die bereits im Studiendesign festgelegt werden, wird vermieden. Alle in dieser Arbeit angewandten Filter sind so ausgelegt, dass sie bedarfsgerecht auf die aufgezeichnete Datenmenge entworfen werden.

3.2 Aufbau und Definition der Fahrstudie

Aus der Forschungsfrage aus Abschnitt 2.8 ergeben sich Anforderungen und Rahmenbedingungen für die Studie, aus denen sich das Studiendesign ergibt.

Fahrdaten

Für die vorliegende Studie werden alle Fahrten innerhalb eines definierten Zeitraums aufgezeichnet und analysiert.

Eine Fahrt wird definiert als die Bewegung des Versuchsträgers für eine Fahrstrecke von minimal 2 km. Der Datensatz einer Fahrt umfasst die Daten aller aufgezeichneten Signale zwischen dem Zeitpunkt des Zündungsstarts bis zur Zündungsabschaltung.

Kurzstrecken unter 2 km sind für die Identifikationsziele dieser Arbeit von geringem Interesse. Eine Begründung dieser Aussage folgt in Abschnitt 4.1.

Versuchsträger

Als Identifikationsobjekt dient der Pkw des Fachgebiets Mechatronik der Universität Duisburg-Essen (Deutschland). Es handelt sich bei dem Fahrzeug um einen Ford C-Max Energi Plug-In Hybrid aus dem Baujahr 2013. Dieser ist als US-Import in Deutschland zugelassen (Zulassungsjahr 2013). Der Ford C-Max Energi Plug-In Hybrid zählt zur Fahrzeugklasse der Kompaktvans und hatte zu Beginn der Studie bereits eine gesamte Fahrstrecke von 130.400 km vorzuweisen. Das Fahrzeug wird im weiteren Verlauf der Arbeit als Versuchsträger bezeichnet. Weitere Informationen zum Versuchsträger können Anhang A entnommen werden.

Probanden

Der Versuchsträger kann von allen Mitarbeiterinnen und Mitarbeitern der Organisation, im Folgenden Probanden genannt, genutzt werden. Hierzu zählen wissenschaftliches und technisches Personal sowie studentische Hilfskräfte, die einen gültigen Führerschein der Klasse B besitzen. Der Versuchsträger kann über ein Buchungssystem reserviert und für dienstliche Fahrten genutzt werden. Die Probanden sind darüber in Kenntnis gesetzt, dass Fahrdaten erhoben werden und sie durch die Nutzung des Fahrzeugs Teil einer Studie sind. Alle Probanden haben der Datenaufzeichnung zugestimmt. Weitere Informationen und Instruktionen zum Fahr- und Nutzungsverhalten werden nicht erteilt. Die Probanden sollen sich möglichst natürlich verhalten. Es befinden sich keine weiteren Personen als Beobachter des Versuchs im Versuchsträger. Bei- und Mitfahrer sind im Versuch zulässig, diese übernehmen keine aktive Rolle in der Versuchsdurchführung. Die aufgezeichneten Daten sind vollständig anonymisiert. Es können aus den Daten keine Rückschlüsse auf die Probanden gezogen werden. Eine Checkliste zur Erhebung personenbezogener Daten der Ethikkommission der Universität Duisburg-Essen wurde im Vorfeld der Studie ausgefüllt und kann im Anhang A.7 eingesehen werden. Der Umstand, dass die Probanden darüber informiert wurden, Teil einer Untersuchung zu sein, kann Einfluss auf das Probandenverhalten während der Studie haben (Hawthorne-Effekt, siehe NERDINGER et al. (2008, S. 66)). Der Einfluss dieses Effekts auf die Ergebnisse der Identifikation wird jedoch als gering und vernachlässigbar eingestuft, da nicht das Fahrverhalten der Probanden, sondern die Fahrdynamik des Fahrzeugs untersucht wird.

Zeitraum

Für die Studie werden Fahrdaten aus dem Zeitraum eines Jahres vom 01.07.2019 bis zum 30.06.2020 genutzt. Die Begrenzung des Studienzeitraums auf exakt ein Jahr ist ideal geeignet, um sicherzustellen, dass alle Jahreszeiten und die damit einhergehenden Wetterphänomene, wie Temperaturschwankungen, Niederschläge und Änderungen des Luftdrucks, abgedeckt sind. Ferner sind diese auch in einem möglichst fairen Anteil im Datensatz repräsentiert.

Die zur Verfügung stehenden Messgrößen bieten keine Informationen hinsichtlich der Temperatur, der Fahrbahnbeschaffenheit (Reibwert) oder der Sichtverhältnisse. Daher können diese Größen in der Modellbildung nur als Störgrößen behandelt werden. Es wird vermutet, dass Wetterphänomene erst für hochdynamische Fahrereignisse (transientes Fahrmanöver) relevant werden. Da diese Manöver in naturalistischen Fahrten, die außerhalb des fahrdynamischen Grenzbereichs stattfinden, nicht oder nur sehr selten vorkommen, werden Umwelteinflüsse auf die Datenbasis und die Modellbildung vernachlässigt. Weitere Analysen zum Umwelteinfluss werden in Abschnitt 4.2.2 vorgestellt.

Verkehrsraum

Der Versuchsträger besitzt einen festen Stellplatz am Campus Duisburg der Universität Duisburg-Essen. Das Studiendesign macht keine Vorgaben hinsichtlich des Nutzungsortes des Versuchsträgers. Bedingt durch den Stellplatz und die örtliche Bindung der Probanden zur Universität Duisburg-Essen ist eine Konzentration der Fahrten in und um Duisburg zu erwarten. Duisburg liegt im Westen Deutschlands und ist Teil der Metropolregion Rhein-Ruhr. In der Region sind größtenteils Straßen mit geringem Steigungsprofil zu finden und das Autobahnnetz ist sehr dicht. Der Campus Duisburg ist direkt an den Autobahnen A3 und A40 gelegen.

3.3 Messgrößen und Datenverarbeitung der Fahrstudie

Eine zentrale Anforderung an die Studie, bezogen auf die Sensor- und Messgrößenauswahl, wird bereits in Abschnitt 1.1 dargelegt. Die Messgrößen stammen – mit einer Ausnahme (GPS-Antenne) – von den bereits serienmäßig verbauten Sensoren. Diese Anforderung an das Studiendesign korreliert in idealer Weise mit der zentralen Forderung von NDS, dass die Messsensorik unauffällig im Fahrzeug platziert werden muss (siehe Abschnitt 3). Ansonsten besteht die Gefahr, dass sich der Proband unnatürlich verhält, da ihm ständig bewusst ist, dass er beobachtet wird.

Der Versuchsträger wird nachträglich mit einer zusätzlichen GPS-Antenne ausgestattet. Die Anpassung am Messaufbau verstößt gegen zwei getroffene Anforderungen des Studiendesigns und wird daher kurz diskutiert. Zum einen wird das Studiendesign nachträglich und somit während der laufenden Studie geändert. Dies hat zur Folge, dass für die ersten Studienfahrten keine GPS-Signale vorliegen. Zum anderen wird ein nicht fahrzeugeigener Sensor verwendet. Die GPS-Information ist für die Identifikation nicht notwendig. Für Analysen der Versuchsträgernutzung ist die GPS-Information nützlich, sodass diese hier zum Einsatz kommt. Der Identifikationsprozess aus Abschnitt 3.1.1 wird nicht gestört und das Forschungsvorhaben wird nicht beeinflusst. Die Integration des Signals ist daher unproblematisch und kann ohne Unterbrechung oder Neubeginn der Studie durchgeführt werden.

3.3.1 Datenzugriff und Datenspeicherung

Der Datenzugriff über den DLC wird in Abschnitt 2.4.3 beschrieben. Für die Aufzeichnung der Daten wird ein Datenlogger genutzt. Der Datenlogger übernimmt die Kommunikation mit dem Gateway und führt das Senden und Empfangen der Diagnosenachrichten sowie das Speichern derselben aus. Ein Datenlogger wurde für die spezifischen Anforderungen der Studie entwickelt. Der Datenlogger basiert auf einem Einplatinencomputer und verwendet für die Kommunikation mit dem Gateway des Fahrzeugs ein CAN-Board. Die

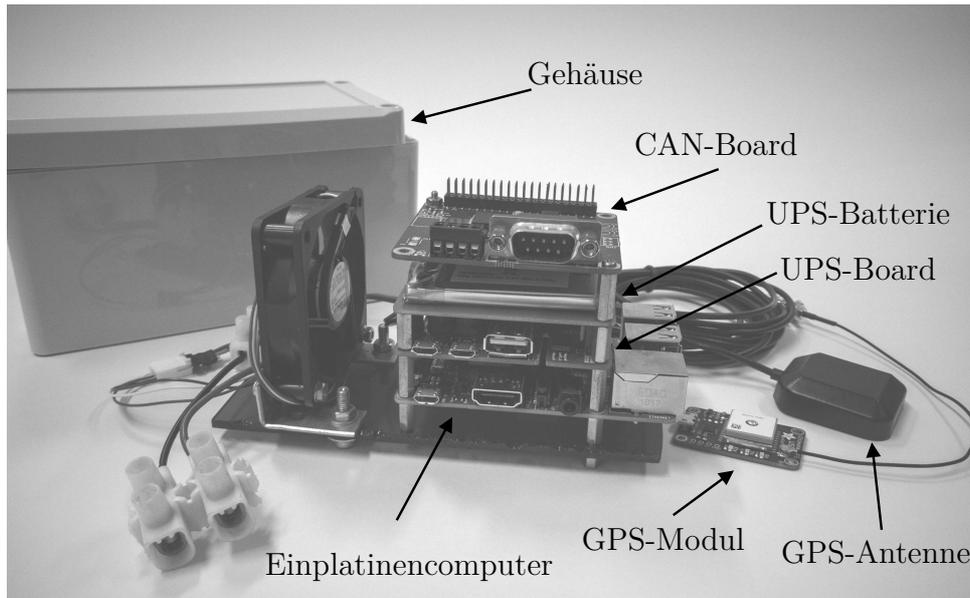


Abbildung 3.2: Aufbau und Komponenten des Datenloggers der Fahrstudie

Spannungsversorgung erfolgt über die 12-V-Bordspannung des Versuchsträgers. Der Datenlogger ist mit einer zusätzlichen unterbrechungsfreien Stromversorgung ausgestattet, sodass dieser, nach dem Ausschalten der Zündung und dem damit einhergehenden Verlust der Versorgungsspannung, weiterhin ordnungsgemäß heruntergefahren werden kann. Weiterhin werden durch die unterbrechungsfreie Stromversorgung etwaige Schwankungen in der Versorgungsspannung abgepuffert. Eine Auflistung der verwendeten Bauteile ist in Tabelle A.1 im Anhang zu finden, eine Darstellung des Datenloggers ist in Abbildung 3.2 gegeben. Auch für die Kommunikation mit dem Gateway wird eine eigenständige Lösung genutzt, diese wird in REICHERTS, SCHRAMM (2020) beschrieben.

3.3.2 Messgrößenauswahl und Definition der Abtastraten

Als Messgrößen werden eine möglichst große Auswahl fahrdynamischer Größen definiert. Der Identifikationsprozess für NDS wird am Beispiel der Querdynamik präsentiert. Für die Modellbildung in Kapitel 5 sind die Messgrößen (Systemeingänge: Lenkwinkel δ_H und Fahrzeuggeschwindigkeit v_x , Systemausgang: Fahrzeugquerbeschleunigung a_y) unverzichtbar. Für die Beschreibung der Querdynamik ist die Gierrate $\dot{\psi}$ eine weitere interessante Größe. Da die Gierrate $\dot{\psi}$ aus technischen Gründen nicht über den gesamten Studienzeitraum verfügbar war und nicht vollständig aufgezeichnet werden konnte, wird auf eine Nutzung dieser Größe im weiteren Verlauf der Arbeit verzichtet. Weitere Größen, die mehrheitlich der Längsdynamik zugeordnet werden können, werden zusätzlich aufgezeichnet. Für eine NDS ist es sinnvoll, so viele Signale wie möglich zu messen, wenn die nicht die eigentliche Messung stören oder die Kosten unverhältnismäßig in die Höhe treiben (SAGBERG et al., 2011, S. 29).

Aufgrund der Kommunikationsarchitektur des Diagnose-CANs muss neben der Messgröße das Intervall festgelegt werden, in welchem die Messgröße zyklisch angefragt wird. Für den Diagnose-CAN ist die Botschaftsrate verglichen mit anderen On-Board-Bussen niedrig (siehe Tabelle 2.4). Werden Diagnoseanfragen in zu kleinen Intervallen auf den Bus gesendet, kann der Bus überlastet werden und es werden keine Diagnoseantworten versendet. Bei zu großen Intervallen kann das Abtasttheorem (siehe Abschnitt 2.4.1) nicht eingehalten werden.

Bei der Definition der Messgrößen muss ein Kompromiss zwischen Anzahl der gemessenen Größen und der Nachrichtenrate der einzelnen Messgrößen gefunden werden. Dieser stellt sicher, dass die für die Identifikation notwendigen Signale in ausreichender Nachrichtenrate aufgezeichnet werden und dass die Studie über einen möglichst großen Signalamfang verfügt. Die erfassten Dynamikgrößen des Starrkörpers (Fahrzeugaufbau) werden mit durchschnittlich 6,8 Hz, die Stellgrößen des Fahrers von 4,1 Hz bis 6,8 Hz erfasst. Eine vollständige Liste aller in der Studie aufgezeichneten Messgrößen und deren Abtastrate ist Anhang A.2 zu entnehmen. Den einzelnen Fahrzeugteilsystemen können unterschiedliche Frequenzbereiche zugeordnet werden. Für diese Arbeit wird die Aufbaubewegung betrachtet. Der zugehörige Frequenzbereich liegt zwischen 1 Hz und 2 Hz (SCHRAMM, HILLER et al., 2018, S. 10). Die für die Querdynamik wesentlichen Zusammenhänge können mit dem Einspurmodell beschrieben werden (siehe Kapitel 5). Die Systemfrequenzen des Einspurmodells liegen gemäß SCHRAMM, HILLER et al. (2018, S. 11) zwischen 0 Hz und 2 Hz. Folglich müssen Systemeingänge und -ausgänge (Messgrößen v_x , δ_H und a_y) im Hinblick auf das Abtasttheorem (siehe Abschnitt 2.4.1) mit mindestens der doppelten Frequenz, also 4 Hz, erfasst werden. Das Abtasttheorem wird für die Messgrößen und Anforderungen der Identifikation erfüllt. Eine korrekte Rekonstruktion des Signals ist hierdurch allerdings nicht garantiert. In praktischen Anwendungen werden häufig Vielfache der minimalen Abtastfrequenz gewählt, um Fehler bei der Signalverarbeitung zu vermeiden. Aus technischen Gründen war bei der vorliegenden Studie die Realisierung einer höheren Abtastrate nicht möglich. Weitergehende Betrachtungen im Hinblick auf die realisierten Abtastraten und mögliche Messfehler durch die Signalverarbeitung sind in Anhang A.3.1 und A.3.2 zu finden.

3.4 Verarbeitungsschritte der Studiendaten

Die vom Gateway kommenden CAN-Diagnosenachrichten werden in einer Messdatei gespeichert. In dieser werden zusätzlich zur CAN-Nachricht auch der zugehörige Zeitstempel des Signalempfangs am Logger vermerkt. Das CAN-Diagnosesignal ist Trägersignal der Datenpakete der einzelnen Messsignale der Fahrstudie. Diese sind über die PID und SID spezifiziert (siehe Abschnitt 2.4.4). Das CAN-Diagnosesignal wird in Subsignale entsprechend der Identifier unterteilt. Diese werden wiederum in die physikalischen Messgrößen umgewandelt und in einem eigenständigen Signalvektor mit zugehörigem Zeitstempel gespeichert.

Abtastumsetzung

Die Signale der einzelnen Messgrößen liegen in ungleichmäßigen Abtastintervallen vor. Für die weitere Verarbeitung wird eine äquidistante und allen Messgrößen zugrunde liegende Signalrate gefordert. Die Abtastumsetzung wird in zwei Schritte unterteilt. Im ersten Schritt wird die Abtastung auf ein äquidistantes Raster umgesetzt, im zweiten Schritt wird die Abtastrate angepasst.

- **Abtastumsetzung auf äquidistantes Raster**

Für die Änderung der Abtastrate eines Signals von nicht äquidistant zu äquidistant, s_0 zu s_a , wird die ursprüngliche Abtastrate auf deren durchschnittliches Intervall umgesetzt. Messwerte werden linear auf das neue Abtastraster interpoliert. Die durchschnittliche Abtastung bleibt erhalten. Der Faktor der Abtastumsetzung ist 1. Der Messwert zum Zeitpunkt $t_n = 0$ s wird geschätzt.

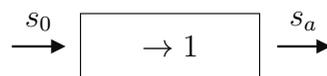


Abbildung 3.3: Abtastumsetzung eines Signals auf ein äquidistantes Raster

- **Abtastumsetzung um rationale Verhältnisse**

Die Messsignale mit ihren unterschiedlichen Abtastraten (siehe Tabelle A.2 im Anhang) werden auf eine einheitliche Abtastrate moduliert. Die Änderung der Abtastrate der Signale wird mittels Abtastumsetzung um ein rationales Verhältnis C_P/C_Q mit $C_P, C_Q \in \mathbb{N}$ realisiert. Die Funktionsweise kann in CROCHIERE, RABINER (1983) und MERTINS (2020) nachgelesen werden. Der Ablauf der Abtastumwandlung ist in Abbildung 3.4 dargestellt.

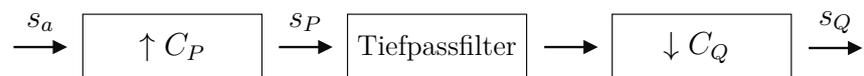


Abbildung 3.4: Abtastumsetzung eines Signals um ein rationales Verhältnis

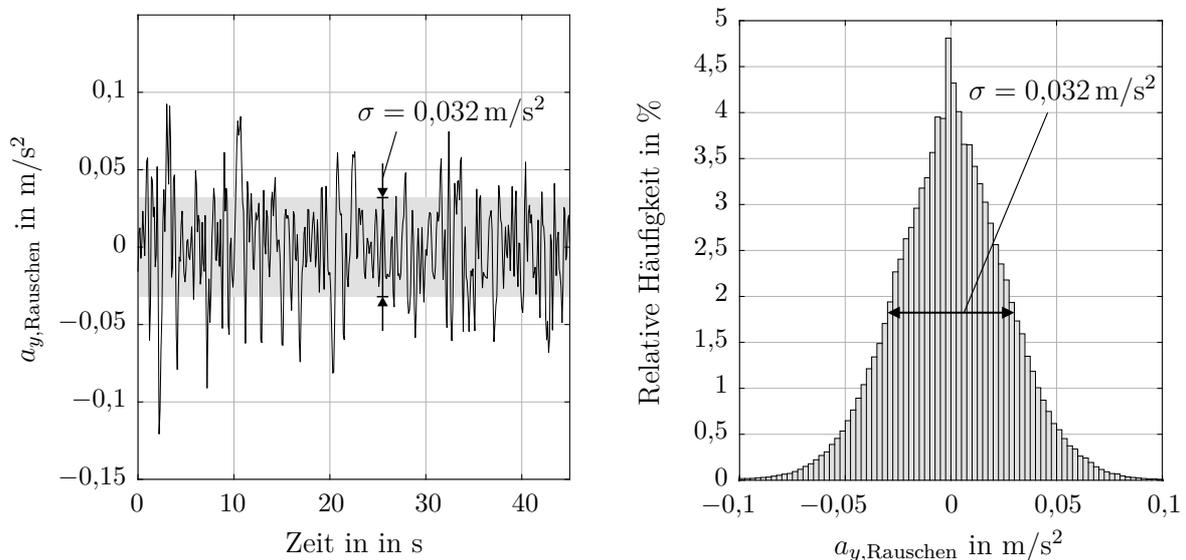
Das äquidistante Signal s_a wird zunächst um den Faktor C_P aufwärtsgetastet. Im Anschluss tiefpassgefiltert und schließlich um den Faktor C_Q abwärtsgetastet. Der Tiefpassfilter verhindert, dass bei der nachfolgenden Abwärtstastung Aliasing entsteht (MERTINS, 2020). Am Ausgang der Prozessschritte liegen die Signale aller Messgrößen mit einer äquidistanten Abtastung von 10 Hz vor. Eine Abschätzung des maximalen Fehlers, der bei der Abtastumsetzung entstehen kann, ist in Anhang A.3.2 beschrieben. Weitere anwendungs- sowie signalspezifische Aufbereitungsschritte und Filter werden in Anhang A.3 vorgestellt.

3.5 Limitierung des Querbeschleunigungsmesswerts

Der Messwert der Querbeschleunigung ist, wie alle Messwerte, störgrößenbehaftet. Zu unterscheiden ist dabei allgemein zwischen generellem Rauschen, wie es für jeden analogen Sensor zu beobachten ist, und Messfehlern aufgrund des speziellen Einsatzgebiets im Fahrzeug. Das generelle Rauschen kann in Abbildung 3.5a gesehen werden und die Verteilung in Abbildung 3.5b. Die Verteilung von $a_{y,\text{Rauschen}}$ im Stand zeigt eine Normalverteilung für das Messrauschen mit einer Standardabweichung von $\sigma = 0,032 \text{ m/s}^2$. Als Identifikationsmethode wird in Kapitel 5 das Verfahren der kleinsten Fehlerquadrate verwendet. Dieses ist robust bei einer normalverteilten Störung, sodass das Identifikationsergebnis durch das Messrauschen nicht wesentlich beeinflusst wird (ISERMANN, 1992).

Für die Messung der Querbeschleunigung ist das Zusammenspiel der Bewegung des Fahrzeugs im Raum und den Sensorwerten von besonderem Interesse. Zur Beschreibung wird ein horizontiertes Hilfskoordinatensystem $\mathbf{K}_H = \{O_H; x_H, y_H, z_H\}$ eingeführt (siehe ISO 8855 und Abbildung 3.6a). Der Ursprung O_H ist identisch zum Ursprung des fahrzeugfesten Koordinatensystems O_V . Die Ebene, die durch Achsen x_H und y_H aufgespannt wird, ist parallel zur Horizontalebene. Die x_H -Achse ist die Projektion der x_V -Achse auf die Horizontalebene.

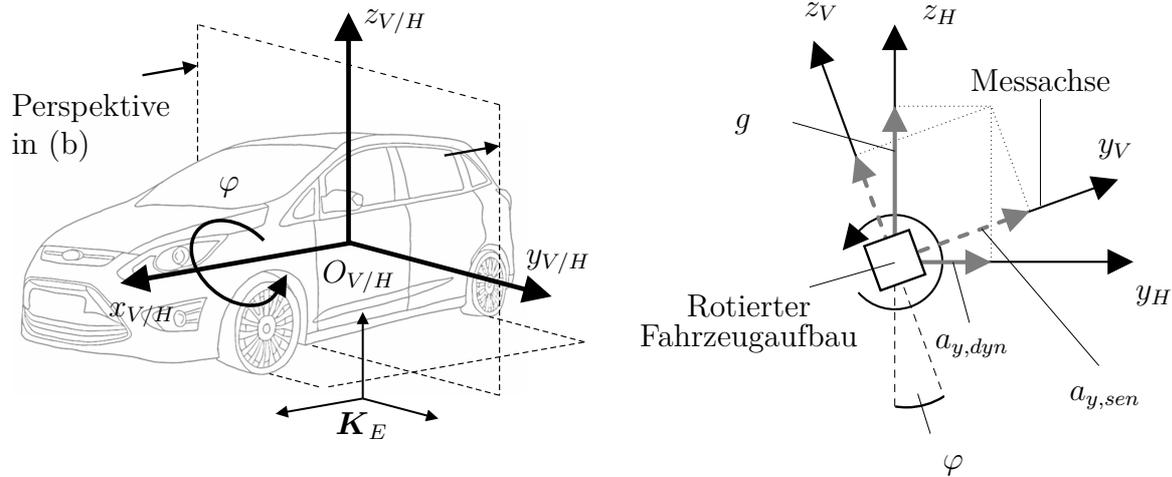
Ein im Versuchsträger fest verbauter Sensor erfasst Beschleunigungen in drei Raumrichtungen. Eine Rotation des Bezugssystems, in diesem Fall des Versuchsträgers, führt auch zu einer Rotation des Beschleunigungssensors. Für die Einbaulage des Beschleunigungs-



(a) Messrauschen des Querbeschleunigungssignals $a_{y,\text{sen}}$ im Stand

(b) Verteilung des Messrauschens über alle Stillstandphasen der Fahrstudie

Abbildung 3.5: Messrauschen $a_{y,\text{Rauschen}}$ des analogen Beschleunigungssensors der Messgröße $a_{y,\text{sen}}$



(a) Positionierung des horizontalen Koordinatensystems K_H im Versuchsträger (b) Rotation des fahrzeugfesten Koordinatensystems relativ zum horizontalen Koordinatensystem

Abbildung 3.6: Einfluss der Wankbewegung des Fahrzeugaufbaus auf den Messwert der Querbeschleunigung $a_{y,sen}$. Die Gravitation g ist aufgrund des Messprinzips des Sensors positiv dargestellt.

sensors wird die idealisierte Annahme getroffen, dass sich dieser auf der Wankachse des Fahrzeugs befindet und dass die Messachsen des Beschleunigungssensors koaxial zu den Achsen des fahrzeugfesten Koordinatensystems K_V sind. Bei einer Rotation des Versuchsträgers wird das fahrzeugfeste Koordinatensystem K_V und somit auch die Messachse des Sensors relativ zum horizontalen Koordinatensystem K_H verdreht, was eine Verzerrung des Messwertes zur Folge hat.

Im Weiteren wird die Rotation um die x_V -Achse, die Wankrotation, betrachtet. Andere Rotationen werden vernachlässigt. Die Beschleunigungen im Schwerpunkt des Versuchsträgers sollen in K_H gemessen werden. Es wird die Querbeschleunigung $a_{y,dyn}$ im Schwerpunkt des Versuchsträgers betrachtet, die beim Durchfahren einer Kurve entsteht. Diese ist parallel zur y_H -Achse des horizontalen Koordinatensystems. In Abbildung 3.6b sind die auf den Beschleunigungssensor wirkenden Beschleunigungen dargestellt. Die vom Sensor gemessene Querbeschleunigung wird mit $a_{y,sen}$ bezeichnet.

Eine Rotation des Fahrzeugkoordinatensystems um die x_H -Achse führt zu einer Differenz zwischen $a_{y,dyn}$ und $a_{y,sen}$, sodass $a_{y,dyn} \neq a_{y,sen}$ ist. In Abbildung 3.6b wird die Ausgabe des Sensors $a_{y,sen}$ unter dem Einfluss verschiedener Beschleunigungen in einem um φ rotierten Koordinatensystem dargestellt. Neben der Querbeschleunigung $a_{y,dyn}$ wirkt die Gravitation g auf den Schwerpunkt. Bei einer Rotation des Fahrzeugaufbaus um den Wankwinkel φ wird infolge der Aufbaurotation die Messachse y_V des Beschleunigungssensors rotiert. Die Querbeschleunigung $a_{y,dyn}$ wird nur noch anteilig erfasst. Im Gegenzug

wird die Gravitation anteilig auf die Messachse y_V projiziert. Die Beschleunigungen aus \mathbf{K}_H können in \mathbf{K}_V ausgedrückt werden.

$$\underbrace{\begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\varphi) & \sin(\varphi) \\ 0 & -\sin(\varphi) & \cos(\varphi) \end{bmatrix}}_{\text{Rotationsmatrix um } x} \underbrace{\begin{bmatrix} 0 \\ a_{y,\text{dyn}} \\ g \end{bmatrix}}_{\text{Beschl. in } \mathbf{K}_H} = \underbrace{\begin{bmatrix} 0 \\ \cos(\varphi)a_{y,\text{dyn}} + \sin(\varphi)g \\ -\sin(\varphi)a_{y,\text{dyn}} + \cos(\varphi)g \end{bmatrix}}_{\text{Beschl. im fahrzeugfesten KS. } \mathbf{K}_V} \quad (3.1)$$

mit: $a_{y,\text{dyn}}$ = durch Fahrdynamik induzierte Querbeschleunigung
 g = Gravitationsbeschleunigung ($g = 9,81 \text{ m/s}^2$)
 φ = Wankwinkel

3.5.1 Rotationseinflüsse auf den Querbeschleunigungsmesswert

Der Messwert der Querbeschleunigung $a_{y,\text{sen}}$ und der gesuchte reale Querbeschleunigungswert $a_{y,\text{dyn}}$ unterscheiden sich aufgrund verschiedener Effekte. Neben dem Messrauschen wird die Abweichung in der Querbeschleunigung hauptsächlich durch eine Rotation der Messachse y_V verursacht. Die wesentlichen Rotationseffekte werden in statische und dynamische Rotationsanteile aufgeteilt. Nicht alle Effekte lassen sich eindeutig einer Gruppe zuordnen. Für diese Größen wird nur der Haupteffekt diskutiert und die vereinfachende Modellannahme getroffen, dass die Kopplung zu weiteren Effekten vernachlässigt werden kann.

- **Dynamischer Wankwinkel** φ_{dyn}

Die auf das Fahrzeug wirkenden Kräfte, welche die Lateralbewegung des Fahrzeugs verursachen, resultieren in einem Wankmoment (Eine genaue Beschreibung der Zusammenhänge wird in SCHRAMM, HILLER et al. (2018) gegeben.). Hieraus ergibt sich eine Rotation des Aufbaus um den Wankpol. Der Rotationswinkel wird als Wankwinkel φ_{dyn} bezeichnet. Die Ausprägung des Wankwinkels resultiert aus einer komplexen Wankdynamik des Versuchsträgers. Änderungen der Fahrzeugbeladung haben Einfluss auf die Wankdynamik.

- **Statischer Wankwinkel** φ_{stat}

Als statischer Wankwinkel wird der Wankwinkelanteil bezeichnet, der sich im Stillstand des Versuchsträgers einstellt. Dessen Haupteinflussgrößen sind die Straßenquerneigung η und eine asymmetrische Fahrzeugbeladung φ_B . Es gilt, dass $\varphi_{\text{stat}} = \eta + \varphi_B$ ist.

- **Querneigungswinkel der Fahrbahnebene** η

Eine Querneigung der Straße führt zu einer Rotation des Fahrzeugaufbaus. In DACHROTH (1992) wird eine Übersicht zu den deutschen Bauvorschriften gemäß der Richtlinie für die Anlage von Straßen gegeben. Grundsätzlich ist

eine Mindestneigung von 2,5 % zum Abfluss von Niederschlägen vorzusehen. In der Regel wird die Straße senkrecht zur Fahrtrichtung nach außen ($\eta > 0$) geneigt. Allerdings existieren einige Ausnahmen. Eine relevante Ausnahme der senkrecht zur Fahrtrichtung nach außen geneigten Straßen besteht für die Straßenneigung in Kurven auf Autobahnen. Auf Autobahnen werden zur Kompensation hoher Fliehkräfte in Kurven Querneigungen zur Kurveninnenseite bevorzugt, sodass für Linkskurven die Querneigung invertiert werden muss ($\eta < 0$). Diese Invertierung führt zu Verwindungen der Straße, die wiederum grundsätzlich vermieden werden sollen. Daher besagen weitere Richtlinien, dass für große Kurvenradien mit geringeren Querbeschleunigungen Querneigungen zur Kurvenaußenseite zulässig sind. (BAIER, 2012; ROHLOFF, 2008)

– **Asymmetrische Fahrzeugbeladung φ_B**

Personen im Fahrzeug sowie weitere Beladung verändern das Gewicht des Versuchsträgers und sehr wahrscheinlich auch die Schwerpunktlage des Systems. Wird die Schwerpunktlage durch zusätzliches Gewicht seitlich zur Wankachse versetzt, so verursacht die Gravitationskraft ein Wankmoment. Das Wankmoment wiederum verursacht einen Wankwinkel φ_B .

3.5.2 Messfehler durch einen Wankwinkel

Die im Messwert enthaltenen Störanteile können nicht vollständig erfasst werden. Es wird daher ein Modell, das den Zusammenhang aus $a_{y,\text{sen}}$ und $a_{y,\text{dyn}}$ beschreibt, aus den verfügbaren Informationen abgeleitet. Das Sensormodell

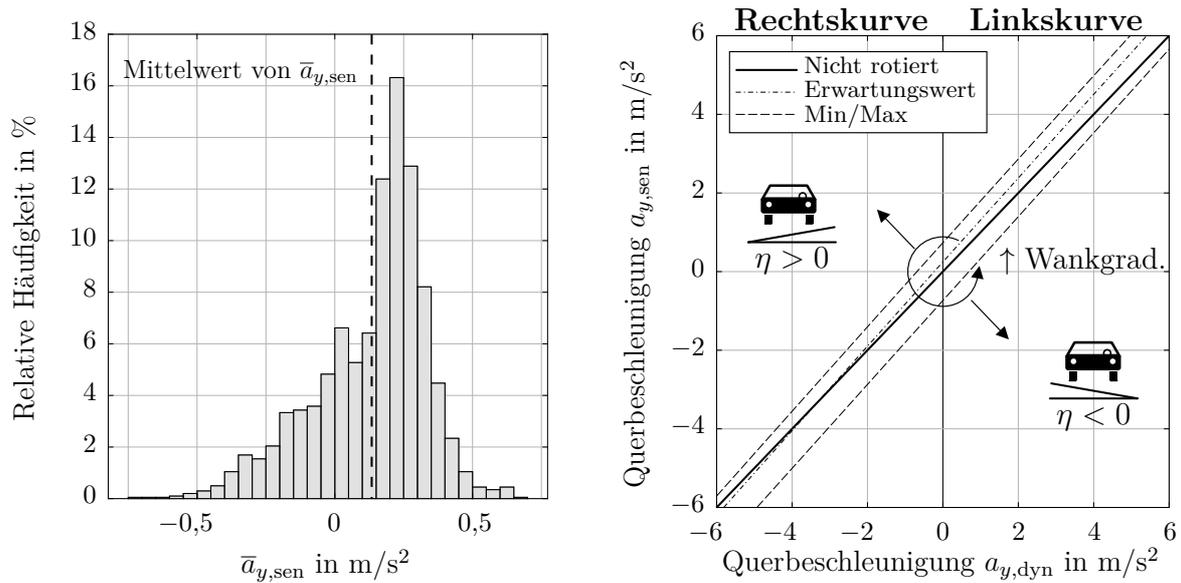
$$a_{y,\text{sen}} = \underbrace{\cos(\varphi_{\text{dyn}} + \varphi_{\text{stat}})a_{y,\text{dyn}} + \sin(\varphi_{\text{dyn}} + \varphi_{\text{stat}})g}_{\text{Rotation des Fahrzeugaufbaus}} + \underbrace{(a_{y,\text{Rauschen}})}_{\text{Sensorrauschen}} \quad (3.2)$$

- mit:
- $a_{y,\text{dyn}}$ = durch Fahrdynamik induzierte Querbeschleunigung
 - $a_{y,\text{Rauschen}}$ = Querbeschleunigungsanteil durch Sensorrauschen
 - $a_{y,\text{sen}}$ = gemessene Querbeschleunigung
 - g = Gravitationsbeschleunigung
 - η = Querneigungswinkel der Fahrbahnebene
 - φ = Wankwinkel ($\varphi = \varphi_{\text{dyn}} + \varphi_{\text{stat}}$)
 - φ_B = Wankwinkelanteil durch Beladung
 - φ_{dyn} = dynamischer Wankwinkelanteil, durch $a_{y,\text{dyn}}$ hervorgerufen
 - φ_{stat} = statischer Wankwinkelanteil aus $\varphi_{\text{stat}} = \eta + \varphi_B$

setzt sich aus der Rotationsgleichung 3.1 und einem Rauschterm zusammen. Der Wankwinkel φ ist die Summe aus dynamischen und statischen Wankanteilen.

Das dynamische Wankverhalten des Versuchsträgers wird mittels Vergleichssimulation näherungsweise bestimmt. Hierfür werden Simulationsdaten einer stationären Kreisfahrt für einen Ford C-Max Diesel 2.0 l¹⁹ analysiert. Es wird der Zusammenhang aus

¹⁹Simulationsdaten eines validierten ADAMS/Chassis-Modells bereitgestellt durch die Ford-Werke GmbH



(a) Mittlere gemessene Querbeschleunigung $\bar{a}_{y,\text{sen}}$ je Standphase (b) Residuum zwischen den Querbeschleunigungen $a_{y,\text{sen}}$ und $a_{y,\text{dyn}}$

Abbildung 3.7: Verteilung des Rotationseinflusses in Stillstandphasen sowie Darstellung des Sensormodells für verschiedene Kombinationen der Störeinflüsse

$a_{y,\text{sen}} = \cos(\varphi_{\text{dyn}})a_{y,\text{dyn}} + \sin(\varphi_{\text{dyn}})g$ untersucht. Die Analyse zeigt, dass der Zusammenhang aus $a_{y,\text{sen}}$ und $a_{y,\text{dyn}}$ für die auftretenden Winkel näherungsweise linear ist. Für einen Querbeschleunigungswert von $a_{y,\text{dyn}} = 1 \text{ m/s}^2$ wird ein Sensorwert von $a_{y,\text{sen}} = 1,07 \text{ m/s}^2$ erfasst. Die relative Messabweichung $\frac{a_{y,\text{sen}} - a_{y,\text{dyn}}}{a_{y,\text{dyn}}}$ ist etwa 7 %.

Die weiteren Störgrößenanteile lassen sich sehr gut in Stillstandsphasen analysieren. Im Stillstand ($v_x = 0 \text{ m/s}$) vereinfacht sich Gleichung 3.2. Die dynamische Querbeschleunigung $a_{y,\text{dyn}}$ und der dynamische Wankwinkel φ_{dyn} sind 0 m/s^2 bzw. 0 rad , sodass $a_{y,\text{sen}} = \sin(\varphi_{\text{stat}})g + a_{y,\text{Rauschen}}$ gilt. Es wird weiter angenommen, dass $\dot{\varphi}_{\text{stat}} = 0 \text{ rad/s}$ und dass das Rauschen mittelwertfrei ist: $\bar{a}_{y,\text{Rauschen}} = 0 \text{ m/s}^2$. In diesem Fall können die beiden Teile der Gleichung entkoppelt betrachtet werden. In Abbildung 3.7a sind die Mittelwerte $\bar{a}_{y,\text{sen}}$ einzelner Standphasen als Häufigkeitsverteilung dargestellt. Die Verteilung weist eine große Streuung mit Maxima bei $\pm 0,75 \text{ m/s}^2$ auf. Am häufigsten werden Beschleunigungen im Intervall von $0,2 \text{ m/s}^2$ bis $0,25 \text{ m/s}^2$ beobachtet.

Die gemessenen Beschleunigungswerte im Stillstand setzen sich aus Anteilen aus Straßenquerneigung und Fahrzeugbeladung zusammen. Der Wankwinkel durch Straßenquerneigung η ist in der Regel deutlich größer als der Wankwinkel φ_B durch zusätzliche Beladung. Ein Fahrer mit einem Gewicht von 90 kg verursacht einen, über mehrere Messungen gemittelten, Messausschlag von etwa $0,02 \text{ m/s}^2$. Dem gegenüber steht ein Beschleunigungswert von $0,25 \text{ m/s}^2$ für eine Straßenquerneigung von $2,5 \text{ ‰}$, was der Straßenmindestneigung gemäß DACHROTH (1992) entspricht.

Mit dem Verständnis über den Verlauf und die Größe der Einzeleffekte aus dynamischem und statischem Wankwinkel kann der Messfehler als Funktion der Querbeschleunigung $a_{y,\text{dyn}}$ dargestellt werden. In Abbildung 3.7b ist eine Gegenüberstellung zwischen dem Messwert $a_{y,\text{sen}}$ und dem dynamischen Wert $a_{y,\text{dyn}}$ für unterschiedlich große Störeinflüsse dargestellt. Das Sensorrauschen sowie die Effekte aus asymmetrischer Fahrzeugbelastung werden in dieser Darstellung, aufgrund ihrer Größe im Verhältnis zu den weiteren Störeinflüssen, vernachlässigt. Die durchgezogene Linie zeigt die Referenzlinie $a_{y,\text{sen}} = a_{y,\text{dyn}}$. Mit einer Strich-Punkt-Linie ist der Erwartungswert für eine mittlere Straßenquerneigung von 2,5 % in Kombination mit dem dynamischen Wankwinkel dargestellt. Für Rechtskurven sind die Wankwinkelanteile φ_{dyn} und φ_{stat} gegenläufig, sodass sich im Beschleunigungsintervall von $a_{y,\text{dyn}} = [-4, -2] \text{ m/s}^2$ die Einflüsse näherungsweise kompensieren. Eine Störgrößenauslöschung während einer Kurvendurchfahrt ist möglich. Hierbei kompensieren sich der Einfluss der dynamischen Wankbewegung des Aufbaus und der Einfluss der Straßenquerneigung. Für Linkskurven verstärken sich die Einflüsse. Die gestrichelten Linien stellen die maximal im Stand erfassten Straßenquerneigungen ($0,75 \text{ m/s}^2$) in Kombination mit der Wankdynamik dar.

Die Pfeile in der Abbildung zeigen an, in welche Richtung die Kurve des Sensormodells für Änderungen am Straßenquerneigungswinkel verschoben wird. Die Steigung der Kurve ist abhängig vom Wankgradienten des Fahrzeugs. Mit steigendem Wankgradienten nimmt die Steigung der Kurve zu. Die große Spreizung der Straßenquerneigungen führt zu einer starken Störung des Messsignals.

3.5.3 Auswirkungen des Messfehlers auf die Identifikation

Die Auswirkungen des Messfehlers für die Identifikation müssen diskutiert werden.

- **Dynamischer Wankwinkel**

Für naturalistische Fahrten sind geringe Querbeschleunigungen zu erwarten. Für Querbeschleunigungen unterhalb von etwa $a_{y,\text{dyn}} \leq 1 \text{ m/s}^2$ befindet sich die Messabweichung in der Größenordnung des Sensorrauschens (siehe Abbildung 3.5b) und die Störung kann sensorisch nicht erfasst werden. Erst für Querbeschleunigungen von etwa $a_{y,\text{dyn}} > 1 \text{ m/s}^2$ wird dieser Effekt als Störung sichtbar.

Für Querdynamikmodelle, die den dynamischen Grenzbereich beschreiben, sollte der Einfluss des dynamischen Wankwinkels beachtet und modelliert werden. Andernfalls wird die Validität der Identifikation gefährdet.

- **Statischer Wankwinkel**

Der statische Wankwinkel (insbesondere die Straßenquerneigung) stellt eine Limitierung im Identifikationsvorhaben dar. Die Straßenquerneigung η kann mit den vorhandenen Mitteln weder sensorisch erfasst, noch durch ein Modell beschrieben werden. Der Messfehler in Stillstandphasen aus Abbildung 3.7a lässt eine Abschätzung der maximal erreichbaren Modellgenauigkeit zu. Der RMSE für die Datenpunkte im Stillstand der Fahrstudie liegt bei $\text{RMSE}_{v_x=0} = \sqrt{\frac{\sum_{i=1}^N (a_{y,\text{sen},i} - a_{y,\text{dyn},i})^2}{N}} = 0,245 \text{ m/s}^2$.

Der Messfehler wird sich vermutlich direkt im Identifikationsergebnis niederschlagen und der RMSE der Identifikation auf die Größenordnung von $\approx 0,25 \text{ m/s}^2$ limitiert sein. Der Fehlerwert wird als akzeptabel eingestuft, da dieser zufällig ist und sich nicht zwangsläufig im identifizierten Modellverhalten widerspiegelt.

Im Vergleich zum statischen Wankwinkel φ_{stat} ist der dynamische Wankwinkel φ_{dyn} für alltägliche Fahrten als gering einzustufen. Der berechnete Verlauf in Abbildung 3.7 zeigt, dass erst für Querschleunigungen oberhalb von etwa 3 m/s^2 der dynamische Wankwinkel größer wird als der statische Wankwinkel.

Die Diskussion des Fehlers wird für die verschiedenen Modellierungsansätze (theoretische und experimentelle Modellbildung, siehe Abschnitt 2.1.1) individuell durchgeführt.

- **Theoretisches Modell**

Der Fehler durch den dynamischen Wankanteil wird als unkritisch für die Identifikation bewertet. Für alltägliche Fahrten sind die auftretenden Querschleunigungen und auch der Fehler sehr klein. Das 90%-Quantil der Querschleunigung liegt bei $a_{y,\text{sen}} = 0,65 \text{ m/s}^2$ (siehe Tabelle 5.1). Der relative Messfehler, der durch die Wankrotation entsteht, ist schätzungsweise 7% und somit ist der absolute Messfehler für 90% aller Fahrdaten $\leq 0,046 \text{ m/s}^2$. Erst für Querschleunigungen außerhalb des in alltäglichen Fahrten üblichen Dynamikbereichs wird der Effekt des Wankens im Ergebnis der Simulation deutlich.

Der statische Wankwinkel kann mit den vorhandenen Messwerten nicht korrekt erfasst oder modelliert werden. Dieser wird zwangsläufig zu einer Abweichung zwischen Messwert und Modellausgabe führen. Die Abweichung ist insofern akzeptabel, als dass diese erklärbar und nachvollziehbar ist. Es ist bei der Modellbildung darauf zu achten, dass der Messfehler nicht in die Parameteridentifikation einfließt und so zu unplausiblen Parametern führt. Dies kann durch die Auswahl einer geeigneten Modellstruktur oder Identifikationsmethode gewährleistet werden.

- **Experimentelles Modell**

Der Querschleunigungsanteil im Messwert, der durch das dynamische Wanken hervorgerufen wird, wird für experimentelle Modelle mit abgebildet und identifiziert. Eine Trennung zwischen dem Sensorwert $a_{y,\text{sen}}$ und dynamischer Querschleunigung $a_{y,\text{dyn}}$ ist nicht möglich. Abhängig von der Anwendung muss entschieden werden, ob dieser Umstand gewollt oder ungewollt ist.

Der Messfehler durch die Straßenquerneigung sowie dessen Einfluss müssen untersucht werden. Ein experimentelles Modell wird die Straßenquerneigung bei den gegebenen Eingängen (Lenkradwinkel und Geschwindigkeit) nicht vollständig erlernen können. Dennoch kann das experimentelle Modell eine gute Robustheit gegen die zufällige Störung zeigen und die Querschleunigung plausibel abbilden.

Daten der Fahrstudie

Mit der Motivation, die Potentiale naturalistischer Fahrdaten für die Identifikation der Fahrdynamik zu untersuchen, wurde eine einjährige naturalistische Fahrstudie durchgeführt. Der Informationsinhalt der Studiendaten hat wesentlichen Einfluss auf das spätere Identifikationsergebnis. Da der Informationsinhalt einzig über die Studiendauer, und selbst das nur begrenzt, beeinflusst werden kann, wird die Datenmenge untersucht und die fahrdynamischen Beobachtungen werden präsentiert. Die Beobachtungen werden zur Einordnung mit anderen Studien verglichen.

4.1 Nutzungsverhalten des Versuchsträgers

Im Studienzeitraum vom 01.07.2019 bis zum 30.06.2020 wurden 360 Fahrten mit einer Gesamtlänge von 9.030 km und einer Dauer von 148 Std. aufgezeichnet. Fahrten mit einer Länge unter 2 km werden gemäß der Definition einer Fahrt (zu finden im Studiendesign in Abschnitt 3.2) ausgeschlossen. Die Analyse der Studiendaten zeigt, dass der Ausschluss der kurzen Fahrten zweckmäßig für die Ziele dieser Arbeit ist. Kurze Fahrten finden vollständig innerorts bei niedrigen Geschwindigkeiten und geringen Querbeschleunigungen statt. Aufgrund des festen Standplatzes des Versuchsträgers an der Universität werden bei diesen Fahrten die Straßen in der direkten Nähe zum Campus Duisburg abgedeckt. Fahrdaten, die aus Fahrten auf diesen Straßen entstammen, liegen im Datensatz vielfach vor, da diese Wege auch bei längeren Fahrten genutzt werden. Folglich liefern die Fahrdaten aus kurzen Strecken keinen Mehrwert für das Identifikationsvorhaben. Gleichzeitig kann die Anzahl der Fahrten um fast ein Viertel reduziert werden. Die Fahrstrecke wird hierbei nur um 2,5 % reduziert, sodass die Maßnahme aus Gründen des Datenmanagements

Tabelle 4.1: Merkmale der aufgezeichneten Fahrdaten im Messzeitraum aufgeteilt in alle Fahrten sowie Fahrten, die länger als 2 km sind. Fahrten > 2 km werden ferner hinsichtlich der Nutzung unterschiedlicher Straßenkategorien klassifiziert.

Anmerkungen: Fahrstrecke (Abk.: FS) und Fahrdauer (Abk.: FD)

¹Der Studienzeitraum besteht aufgrund des Schaltjahres 2020 aus 366 Tagen.

	Alle Fahrdaten		Fahrten > 2 km			
			$Z_{V,Studie}$			
Zeitraum	2019-2020					
Anzahl der Fahrten	360		273			
Fahrstrecke gesamt in km	9030		8800			
Fahrdauer gesamt in Std.	148		140			
Mittlere Fahrstrecke in km	25		32			
Mittlere Fahrdauer in min	25		31			
Mittlere Geschwindigkeit in km/h	61		63			
Anzahl der Fahrten/Tag ¹	0,98		0,75			
Klassifizierung der Daten (Fahrten > 2 km)						
	FS		FD		Standzeit	
	in km	in %	in Std.	in %	in Std.	in %
Gesamt	8800		140		12,5	9
Klassifiziert	5920	100	91	100	3,9	8
Innerorts	910	16	32	35	6,1	19
Überland	370	6	7	8	0,5	7
Autobahn	4640	78	52	57	0,7	1

sinnvoll ist und der Ausschluss quantitativ nicht ins Gewicht fällt. Nach Anwendung des Längenkriteriums reduziert sich der Datensatz $Z_{V,Studie}$ auf 273 Fahrten bei 8.800 km und 140 Std.

Für die weiteren Analysen wird der reduzierte Datensatz verwendet und analysiert. Nur in Ausnahmefällen wird auf den vollständigen Datensatz referenziert, dann mit explizitem Hinweis. Eine Übersicht zu den gesammelten Fahrdaten wird in Tabelle 4.1 gegeben.

Das Konzept einer adäquaten Datenmenge wird in Abschnitt 3.1.2 beschrieben. Für die Studiendaten werden verschiedene Untersuchungen (Messwertbereich, Vergleich mit anderen Studien und statistische Analysen) durchgeführt, um eine Aussage hinsichtlich der Adäquanz der Daten zu treffen.

4.1.1 Beschreibung der Studiendaten

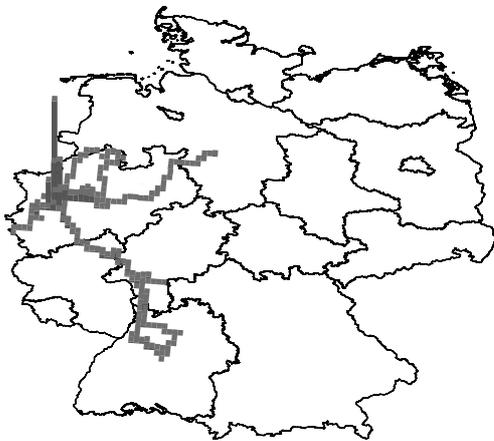
Die Analyse fokussiert sich auf drei Eigenschaften der Studiendaten des Versuchsträgers. Das Bewegungsprofil des Versuchsträgers in Kombination mit der Fahrstrecke wird untersucht. Die Homogenität der Versuchsträgernutzung über den Studienzeitraum wird

analysiert sowie der Verteilung der Straßentypnutzung (Autobahn, Überland, Innerorts) diskutiert.

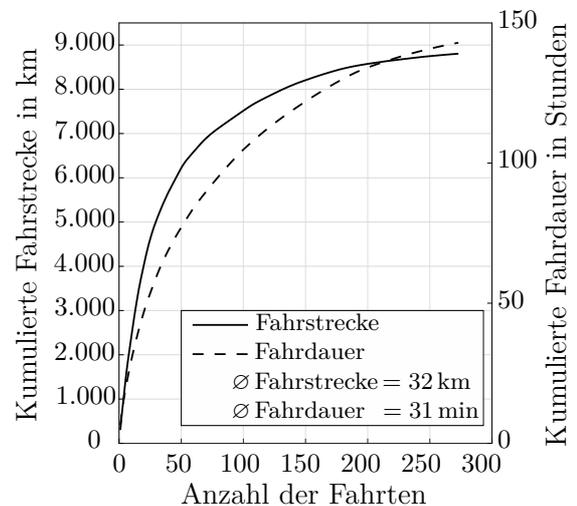
Bewegungsprofil

Die im Studiendesign erwartete Konzentration auf das Ruhrgebiet (siehe Abschnitt 3.2) wird durch die erhobenen Daten bestätigt. Die Auswertung der GPS-Daten zeigt, dass ein Großteil der Fahrten im Bundesland Nordrhein-Westfalen stattfanden. Eine Visualisierung des Bewegungsprofils wird in Abbildung 4.1a gegeben. Die gemessenen GPS-Positionen werden als ein 2D-Histogramm mit unterlegter Deutschlandkarte visualisiert. Die Häufigkeit einzelner GPS-Positionen wird über die Höhe der Balken dargestellt. Lediglich vereinzelte Fahrten reichen über die Bundeslandgrenzen hinaus.

Eine Analyse der kumulierten Fahrstrecke und Fahrdauer in Abbildung 4.1b zeigt, dass wenige Fahrten einen Großteil des aufgezeichneten Gesamtumfanges ausmachen. Die Daten in Abbildung 4.1b sind in absteigender Größe sortiert. Die Verteilung der Fahrstrecke ist ungleichmäßig und der Verlauf der kumulierten Fahrstrecke stark degressiv. Etwa 10 % der Fahrten beinhalten die Daten von 50 % der gefahrenen Strecke. Die durchschnittliche Fahrstrecke beträgt 32 km. Der Verlauf der kumulierten Fahrdauer ist ebenfalls ungleichmäßig und degressiv. Die durchschnittliche Fahrdauer beträgt 31 min.



(a) Bewegungsprofil des Versuchsträgers basierend auf GPS-Daten. Die Häufigkeit der GPS-Messpunkte wird durch die Höhe der Balken repräsentiert.

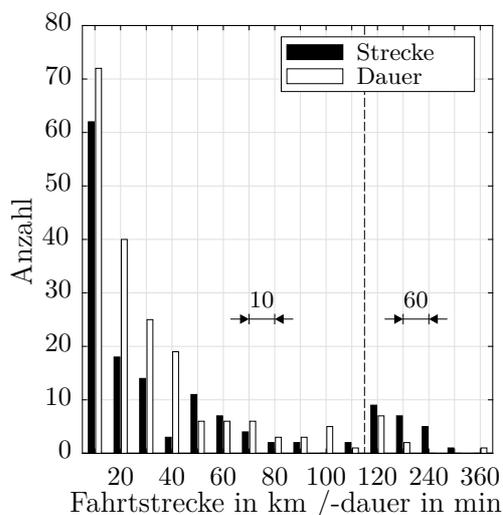


(b) Kumulierte Fahrstrecke und -dauer über den Studienzeitraum. Die Daten sind ihrer Größe nach geordnet.

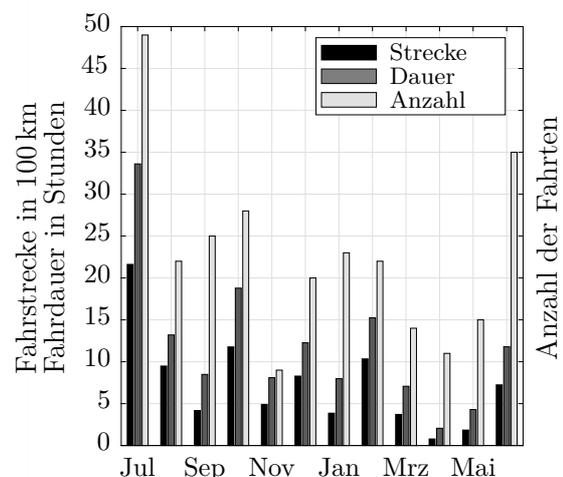
Abbildung 4.1: Übersicht der aufgezeichneten Studiendaten im Zeitraum Juli 2019 bis Juni 2020. In (a) wird die Häufigkeit der GPS-Messpunkte als 2D-Histogramm auf der Deutschlandkarte dargestellt und in (b) die Zusammensetzung der Gesamtstrecke/-dauer aus den einzelnen Fahrten.

Homogenität des Nutzungsverhaltens

Im Datensatz existieren viele kurze und wenige lange Fahrten. Beinahe die Hälfte aller Fahrten ist kürzer als 10 km. Die maximale Fahrtdauer ist 360 min und ist für eine einzelne Fahrt ungewöhnlich lang. Im Datensatz stellt diese einen Ausreißer dar. In Abbildung 4.2a ist die Häufigkeit der Fahrtdauer und -strecke für die einzelnen Fahrten der Studie dargestellt (siehe Abbildung 4.2a). Fahrten über 120 km oder 120 min werden in neuen Gruppen zusammengefasst, da diese im Datensatz nur sehr selten vorkommen. Insgesamt sind nur 10 Fahrten länger als 120 min. Gleichzeitig machen diese den Großteil der gesamten Fahrstrecke/-dauer (siehe Abbildung 4.1b) aus.



(a) Häufigkeit von Fahrtdauer und -strecke über den Studienzeitraum



(b) Messaktivität je Studienmonat, dargestellt sind die Anzahl der Fahrten, die gesamte Fahrtdauer und -strecke je Monat

Abbildung 4.2: Verteilung der zurückgelegten Fahrstrecken/-dauern im Zeitraum von Juli 2019 bis Juni 2020

Das Nutzungsverhalten des Versuchsträgers über die Studienlaufzeit wird in Abbildung 4.2b dargestellt. Die Anzahl der Fahrten, die Fahrstrecke und -dauer sind für die einzelnen Studienmonate aufgetragen. Ein wiederkehrendes Nutzungsmuster ist nicht zu erkennen. Vielmehr unterliegen die einzelnen Studienmonate sehr starken Schwankungen in der Nutzungsintensität. Der Monat der stärksten Nutzung ist der Juli 2019 und somit der erste Monat der Studie. Für diesen Monat liegen Fahrdaten zu über 2.000 km und 30 Std. aus beinahe 50 Fahrten vor. Die große Fahrstrecke dieses Monats kommt u. a. durch eine Dienstreise nach Baden-Württemberg zustande. Demgegenüber steht das Frühjahr 2020, das zu großen Teilen durch die COVID-19-Pandemie²⁰ beeinflusst wurde. Dies spiegelt

²⁰Eingeschränkter Betrieb der Universität Duisburg-Essen aufgrund der COVID-19-Pandemie. Im Zeitraum von März 2020 bis zum Ende der Studie (im Juni 2020) war die Universität in einem reduzierten Betrieb. Dies hat auch zu Einschränkungen bei den Dienstreisen geführt.

sich in einer verminderten Messaktivität wider. In den Monaten März, April und Mai liegt die kumulierte Fahrstrecke bei etwa 600 km und somit deutlich unter dem Studien-durchschnitt.

Straßentyp

Jedem Messpunkt der Studie, für den eine GPS-Position aufgezeichnet wurde, wird der befahrene Straßentyp zugeordnet. Bei der Klassifizierung wird zwischen Innerorts, Überland und Autobahn unterschieden. Die Fahrdaten werden hinsichtlich der Fahrstrecke und der Fahrdauer klassifiziert.

Für etwa 30 % der Messpunkte liegt kein GPS-Signal vor (siehe Abschnitt 3.3), sodass diese nicht klassifiziert werden können. Es wird angenommen, dass die Verteilung der nicht klassifizierten Daten der Verteilung der klassifizierten Daten folgt. Diese These wird durch die Auswertung der Geschwindigkeitsverteilungen im Anhang A.2 gestützt. Die Ergebnisse der Klassifikation werden in Tabelle 4.1 zusammengefasst. Von den insgesamt 140 Std. können 91 Std. klassifiziert werden. Zu über 50 % der Studienzeit wird die Autobahn befahren. Zu einem weiteren Drittel wird der Versuchsträger innerorts²¹ genutzt und nur zu 8 % der Zeit auf Überlandstraßen bewegt. Aufgrund der deutlich höheren Durchschnittsgeschwindigkeiten auf Autobahnen gegenüber städtischen Straßen ist die Aufteilung der Fahrstrecke zu einem noch größeren Teil in Richtung Autobahn verschoben. Mit knapp 80 % der gefahrenen Strecke entfällt der größte Anteil auf Autobahnfahrten. Etwa 9 % der gesamten Fahrdauer entfällt auf Standzeiten. Da diese keine Informationen über die Fahrdynamik liefern, sind Standzeiten für die weitere Auswertung von keinerlei Interesse. Eine detaillierte Auflistung der Klassifikationsergebnisse sind Tabelle 4.1 zu entnehmen.

4.1.2 Vergleichsstudien zur Einordnung der Studiendaten

Für den Vergleich mit anderen Studien müssen Studien und Messgrößen ausgewählt und anschließend analysiert werden. Die Untersuchung ist in mehrere Abschnitte unterteilt. Es wird in Abschnitt 4.1 das Nutzungsverhalten analysiert. In Abschnitt 4.2 werden die dynamischen Messgrößen ausgewertet und hinsichtlich anderer Studien eingeordnet. In dieser Arbeit werden ausschließlich Merkmale des Datensatzes untersucht, bei denen ein Einfluss auf die Menge und Qualität fahrdynamischer Informationen vermutet wird.

Für einen optimalen Vergleich zwischen Studien müssen diese in Bezug auf Studiengröße, Aktualität und dem untersuchten Verkehrsraum ähnlich sein. Im Rahmen dieser Arbeit werden drei Vergleichsstudien (eine Befragung und zwei Fahrstudien) und deren Merkmale diskutiert:

²¹Es werden nur Fahrten > 2 km betrachtet. Es ist zu vermuten, dass sich der Anteil der Innerortsfahrten durch diese Auswahl im Verhältnis zu den Anteilen von Überland- und Autobahnfahrten überproportional verringert.

- **MiD 2017**

In der Studie *Mobilität in Deutschland 2017*²² (Abk.: MiD 2017) wurde das Mobilitätsverhalten deutscher Haushalte im Jahr 2017 untersucht. Im Auftrag des Bundesministeriums für Verkehr und digitale Infrastruktur wurden gut 316.000 Haushalte befragt und interviewt. Bei der Stichprobenauswahl wurde auf Vielfalt bei der Altersstruktur, dem Geschlecht, der Herkunftsregion oder des genutzten Verkehrsmittels der Probanden geachtet. In Kombination mit der umfangreichen Stichprobengröße kann die Studie als repräsentativ für die Mobilität in Deutschland betrachtet werden. (BMVI, 2017)

- **euroFOT (Safe HMI)**

Unter naturalistischen Fahrbedingungen wurden im Projekt euroFOT²³ (Akronym von *European Field Operational Test*) neue intelligente Fahrzeugsysteme in über 1.000 Versuchsträgern erprobt. Die Studie fand in verschiedenen europäischen Ländern statt. An dem Projekt haben u. a. Fahrzeughersteller sowie Automobilzulieferer und Forschungsinstitute im Zeitraum von 2008 bis 2011 zusammengearbeitet. (FABER et al., 2012; SCHOCH et al., 2011)

In Tabelle 4.2 ist eine Auswahl der von METZ et al. (2013) vorgestellten Merkmalen einer Teildatenmenge des Projekts euroFOT aus dem Forschungsschwerpunkt Safe HMI (SCHOCH et al., 2011, S. 52-66) dargestellt. Für diese Arbeit werden ausschließlich die Daten aus euroFOT Safe HMI²⁴ (im weiteren Verlauf der Arbeit mit euroFOT bezeichnet) betrachtet. Der Datensatz umfasst 1 Mil. km, die innerhalb von 15.000 Std. von 115 Probanden gefahren wurden. METZ et al. (2013) weisen einschränkend darauf hin, dass die Probanden der Studie überwiegend bis vollständig männlich und mittleren Alters sind.

- **PREMIUM**

In der Feldstudie PREMIUM²⁵ (Akronym von *Plug-In-, Range-Extender- und Elektrofahrzeuge unter realen Mobilitätsumständen: Infrastruktur, Umweltbedingungen und Marktakzeptanz*) werden für die Analyse von Nutzerverhalten unter realen Bedingungen 196 Fahrzeuge eingesetzt und im Zeitraum von 2015 bis 2017 Daten erfasst. Die Fahrdaten stammen aus Deutschland sowie dem Grenzgebiet zu den Niederlanden und Belgien und umfassen größtenteils Fahrten in Ballungsgebieten. Eine Besonderheit der Studie sind die Antriebsarten der Versuchsträger. Diese teilen sich in rein batterieelektrische Fahrzeuge (*Battery Electric Vehicle*, Abk.: BEV) und batterieelektrische Fahrzeuge mit Reichweitenverlängerer (*Range Extended Electric Vehicle*, Abk.: REEV) auf. Mit 470.000 km und 10.000 Std. aus etwa 50.000 Fahrten ist dieser Datensatz sehr umfangreich. (SCHRAMM, DUDENHÖFFER et al., 2017)

²²<https://www.bmvi.de/SharedDocs/DE/Artikel/G/mobilitaet-in-deutschland.html>

²³<https://www.eurofot-ip.eu/index.html>

²⁴In dieser Arbeit wird ein Teildatensatz der euroFOT-Daten betrachtet. Dieser stammt aus dem Forschungsschwerpunkt euroFOT Safe HMI. Der vollständige euroFOT-Datensatz umfasst neben Pkw auch Lkw und ist als Vergleichsmenge für diese Arbeit ungeeignet.

²⁵<https://www.uni-due.de/mechatronik/forschung/premium>

Tabelle 4.2: Merkmale der Vergleichsstudien

Anmerkungen: Fahrstrecke (Abk.: FS), Fahrdauer (Abk.: FD), Battery Electric Vehicle (Abk.: BEV), Range Extended Electric Vehicle (Abk.: REEV), ^aDaten aus dem Forschungsschwerpunkt euroFOT Safe HMI, ^bPrimärdaten der Studie PREMIUM stammen aus SCHRAMM, DUDENHÖFFER et al. (2017), einzelne Fahrten des Datensatzes wurden von TEWIELE (2020) aussortiert, ^cMerkmal wird in Quelle nicht explizit genannt, kann aber aus anderen Merkmalen geschlussfolgert werden: Bsp. mittlere Fahrgeschwindigkeit = FS gesamt/ FD gesamt

Studiename	MiD 2017	euroFOT ^a	PREMIUM	
Quelle	BMVI, 2017	METZ et al. (2013)	TEWIELE (2020) ^b	
Antrieb	gemischt	Verbrenner	BEV	REEV
Zeitraum	2016-2017	2008-2011	2015-2017	
Anzahl der Fahrten	Befragung	39.700	23.620	26.750
FS gesamt in km	–	1.013.000	160.000 ^c	230.000 ^c
FD gesamt in Std.	–	15.130	3.460	4.050
Mittlere FS in km	16 ^c	27	7	9
Mittlere FD in min	24 ^c	24	10	11
Mittlere Geschwindigkeit in km/h	40 ^c	67 ^c	46 ^c	57 ^c
Anzahl der Fahrten/Tag	1,9	4,75	4,5	4
	euroFOT ^a		PREMIUM	
Anteil in %	FS	FD	FD _{BEV}	FD _{REEV}
Innerorts	17	42	71	62
Überland	16	18	17	18
Autobahn	67	40	12	20

Jährliche Fahrstrecke

Die jährliche Fahrstrecke²⁶ ist eine charakteristische Eigenschaft, die für die Fahrdaten untersucht wird. Es wird nicht davon ausgegangen, dass die jährliche Fahrstrecke Einfluss auf das Identifikationsergebnis hat. Die Analyse der jährlichen Fahrstrecke dient somit lediglich der Einordnung der Datenmenge dieser Arbeit. So kann abgeschätzt werden, welcher Aufwand betrieben werden muss, um eine vergleichbare Datenmenge zu erzeugen. Das Kraftfahrt-Bundesamt gibt die jährliche mittlere Fahrstrecke²⁷ im Kalenderjahr 2019 für Pkw mit Verbrennungsmotoren mit 13.600 km an. Die mit dem Versuchsträger in

²⁶In der Literatur wird die Fahrstrecke teilweise als Fahrleistung bezeichnet (siehe etwa KRAFTFAHRT-BUNDESAMT (2020)). In dieser Arbeit wird der Begriff Fahrstrecke verwendet.

²⁷Die geschätzte Fahrstrecke ist ein zeitraumbezogener Mittelwert, welcher basierend auf dem Zentralen Fahrzeugregister des Kraftfahrt-Bundesamtes gebildet wird. Durch Fahrzeugan- und -abmeldungen wird ein sogenannter mittlerer Fahrzeugbestand auf dem Prinzip der Fahrzeugmonate gebildet (KRAFTFAHRT-BUNDESAMT, 2020).

einem Jahr zurückgelegte Fahrstrecke beträgt etwa 9.000 km (siehe Tabelle 4.1) und liegt somit deutlich unter dem Bundesdurchschnitt aus dem Jahr 2019. Die Differenz kann teilweise durch den pandemiebedingten Rückgang der Fahraktivität im Frühjahr 2020 (vgl. Abbildung 4.2b) erklärt werden. Eine Prognose über die Fahrstrecke ohne Pandemie kann seriös nicht gegeben werden, da die Varianz der Fahraktivitäten der restlichen Messmonate zu groß und ein regelmäßiges Nutzungsmuster nicht zu erkennen ist.

Nutzungsverhalten

Das Nutzungsverhalten lässt Rückschlüsse auf den Aufbau und die Aufteilung des Datensatzes zu. Als repräsentative Grundlage dienen die Studienergebnisse aus MiD 2017²⁸. Für die Studienergebnisse aus dem Jahr 2017 wird angenommen, dass diese im Jahr 2020 weiterhin Gültigkeit haben und etwaige Änderungen²⁹ klein sind und vernachlässigt werden können. Die mittlere Fahrstrecke am Stichtag der Studie liegt im Bundesdurchschnitt bei 16 km und in Metropolregionen, wie bspw. dem Ruhrgebiet, bei 17 km. Die mittlere Fahrdauer beträgt 24 min/Fahrt. (BMVI, 2017, S. 70)

Die Analyse der Studiendaten $Z_{V,Studie}$ aus Tabelle 4.1 zeigt, dass für alle Fahrten (linke Spalte) die mittlere Fahrstrecke bei 25 km/Fahrt und die mittlere Fahrdauer bei 25 min/Fahrt liegt. Für die mittlere Fahrdauer entspricht dies ziemlich genau der repräsentativen mittleren Fahrdauer aus MiD 2017 (24 min/Fahrt). Die mittlere Strecke mit 25 km/Fahrt für die Daten des Versuchsträgers sind etwa 50 % höher als in MiD 2017. Für die Fahrten mit einer Strecke größer als 2 km (siehe Tabelle 4.1, rechte Spalte) liegt die mittlere Strecke bei 32 km/Fahrt und die mittlere Fahrdauer bei 31 min/Fahrt. Beide Merkmale weichen nach oben von der repräsentativen Menge ab.

Da die Studienergebnisse der beiden Studien PREMIUM und euroFOT auch starke Abweichungen zu den Ergebnissen aus MiD 2017 zeigen, wird eine starke Abhängigkeit der Merkmale von der gewählten Stichprobe vermutet. Für die Studie PREMIUM beträgt die mittlere Fahrstrecke 7 km/Fahrt für BEV und 9 km/Fahrt für REEV. Die mittlere Fahrdauer liegt bei 10 min/Fahrt respektive bei 11 min/Fahrt. Beide Kennzahlen liegen etwa 50 % unterhalb der Kennzahlen aus MiD 2017.

Für die Kennzahlen der euroFOT-Studie liegt die mittlere Fahrdauer mit 24 min/Fahrt auf ähnlichem Niveau wie bei MiD 2017 und gleichzeitig ist die Fahrstrecke um 30 % größer. Folglich ist die mittlere Geschwindigkeit der betrachteten Studie deutlich über der mittleren Geschwindigkeit der Referenz. Eine ausführliche Diskussion zum Merkmal Ge-

²⁸Die in der Studie angegebenen Größen beschreiben vor allem die Alltagsnutzung (hierunter fallen bspw. keine Urlaubsfahrten), sodass sich daraus nicht unmittelbar die Nutzungsintensität im Jahresverlauf ableiten lässt. Beispiel: Die durch Schätzung der Befragten erfasste jährliche Fahrstrecke beträgt 14.700 km (siehe BMVI, 2017, S. 70). Dem gegenüber steht die aus der täglichen Nutzung berechnete Fahrstrecke von $11.096 \text{ km/Jahr} = 16 \text{ km/Fahrt} \cdot 1,9 \text{ Fahrten/Tag} \cdot 365 \text{ Tage/Jahr}$ (siehe Tabelle 4.2).

²⁹Die Studie MiD wurde bereits in den Jahren 2002 und 2008 durchgeführt. Die Veränderungen der Kennzahlen über die Studienjahre ist gering (siehe BMVI, 2008, S. 89). Nutzungskennzahlen: 2020 \rightarrow 16 km/Fahrt, 24 min/Fahrt; 2008 \rightarrow 14,7 km/Fahrt, 21 min/Fahrt; 2002 \rightarrow 14,5 km/Fahrt, 22 min/Fahrt

schwindigkeit folgt in Abschnitt 4.2.1. Eine mögliche Erklärung für diese Unterschiede zwischen den Studien sind unterschiedliche Antriebstopologien der Versuchsträger und eine damit einhergehende abweichende Nutzung des Pkws. Eine unikausale Begründung, einzig auf der Antriebstopologie basierend, greift an dieser Stelle allerdings vermutlich zu kurz.

Die Merkmale zum Nutzungsverhalten der repräsentativen Studien sind stark inhomogen. Die Abweichungen der Studiendaten $Z_{V,Studie}$ zu den Vergleichsstudien liegt auf einem ähnlichen Niveau wie die Abweichungen der Vergleichsstudien untereinander, sodass das Nutzungsverhalten für diese Studiendaten $Z_{V,Studie}$ im erwartbaren Rahmen ist.

Aufteilung der verwendeten Straßenkategorie

In TEWIELE (2020, S. 116) wird der starke Einfluss des Straßentyps auf die Fahrweise herausgestellt. Die Fahrweise ist kein Untersuchungsobjekt dieser Arbeit, hat allerdings unmittelbaren Einfluss auf die auftretenden fahrdynamischen Größen. Eine Analyse der Verteilung der Fahrdaten nach Straßentyp erscheint daher sinnvoll.

Die Verteilung nach Straßentyp der Studiendaten aus euroFOT wird METZ et al. (2013, S. 13) entnommen. Die Verteilung aus PREMIUM wird TEWIELE (2020, S. 116) entnommen (BEV und REEV). Die Ergebnisse sind in Tabelle 4.2 zusammengefasst.

Die Fahrdauer der Studiendaten $Z_{V,Studie}$ teilt sich zu 35 % Innerortsfahrten, zu 8 % Überlandfahrten und zu 57 % Autobahnfahrten auf (siehe Tabelle 4.1). Unter den betrachteten Studien ist dies der höchste Autobahnanteil. Der Anteil der Überlandfahrten ist mit 8 % geringer als der Anteil der anderen Studien. Der Anteil der Innerortsfahrten liegt unter dem Anteil der PREMIUM-Daten und leicht unter denen der euroFOT-Daten. Die Verteilung der Studiendaten $Z_{V,Studie}$ und der euroFOT-Daten stimmen im Wesentlichen überein.

Der Autobahnanteil der PREMIUM-Daten ist mit $12\%_{\text{PREMIUM BEV,FD}}$ bzw. $20\%_{\text{PREMIUM REEV,FD}}$ deutlich geringer als der Anteil von $Z_{V,Studie}$ und der Anteil der euroFOT-Daten. Es wird vermutet, dass diese starke Diskrepanz teilweise den unterschiedlichen Antriebstopologien (Verbrennungsmotor, REEV, BEV) der Versuchsträger geschuldet ist. BEV und REEV sind für lange Fahrten bei hohen Geschwindigkeiten auf der Autobahn weniger gut geeignet als Fahrzeuge mit Verbrennungsmotor.

Ferner soll an dieser Stelle auch auf die große Varianz in der Straßentypverteilung in euroFOT (METZ et al., 2013, S. 13) hingewiesen werden. Obwohl sehr ähnliche Fahrzeuge als Versuchsträger genutzt wurden, liegen die Anteile für unterschiedliche Probanden der Studie teilweise 60 Prozentpunkte auseinander. Neben der Antriebstopologie, ist folglich der Einfluss der Probanden für die Straßentypwahl zu beachten.

Für die als repräsentativ eingestufte Studie MiD 2017 liegen keine Informationen zur Verteilung nach Straßentyp vor. Eine Einordnung der Ergebnisse der Klassifizierung wird dennoch durchgeführt. In METZ et al. (2013, S. 15) wird argumentiert, dass bei den euroFOT-Daten ein höherer Anteil an Autobahnfahrten vorliegt, als im repräsentativen Vergleich deutscher Verkehrsteilnehmer. Dies wird mit einer hohen mittleren Wegstrecke

bei vergleichbar geringer mittlerer Wegzeit gegenüber den Studienergebnissen aus MiD 2008 (BMVI, 2008) begründet. Für diese Arbeit liegt der Autobahnanteil oberhalb der euroFOT-Studie, die mittlere Fahrstrecke ist auf vergleichbarem Niveau und die Kennzahlen von MiD 2008 zu MiD 2017 haben sich kaum geändert, sodass die gleiche Argumentation aus METZ et al. (2013, S. 15) auf diese Arbeit angewandt werden kann. Es wird geschlussfolgert, dass der gemessene Anteil an Autobahnfahrten dieser Arbeit mit $[57\%]_{V, \text{Studie}, \text{FD}}$ oberhalb des Bundesdurchschnitts liegt. Dies führt folglich zu einer Minderung der Anteile Innerorts und Überland, wobei der Überlandanteil mit $[8\%]_{V, \text{Studie}, \text{FD}}$ als unterrepräsentiert betrachtet wird. Diese Aussage wird durch die Ergebnisse aus METZ et al. (2013) und TEWIELE (2020) gestützt.

Die Besonderheit der Straßentypverteilung des Datensatzes dieser Studie ist auf die Charakteristika des Verkehrsraums der Region Ruhrgebiet zurückzuführen. Als Metropolregion ist das Ruhrgebiet dicht besiedelt. Große Teile dieser Region werden durch innerstädtische Verkehrsführungen abgedeckt, die durch ein dichtes Autobahnnetz ergänzt werden. Überlandstraßen kommen in geringer Zahl vor. Der geringe Überlandanteil stellt für den Datensatz keine Limitierung dar. Der für diesen Straßentyp charakteristische Geschwindigkeitsbereich wird durch Autobahnfahrten vollständig abgedeckt. Die Analyse der Beschleunigungswerte in Abschnitt 4.2.2 zeigt ferner, dass keine Limitierung durch die Verteilung der Straßentypnutzung entsteht. Die Fahrdaten zeigen eine für die Region charakteristische Verteilung. Verkehrsraum-spezifische Phänomene sind auch für andere Regionen denkbar. Für diese Arbeit entstehen hierdurch keine Limitierungen.

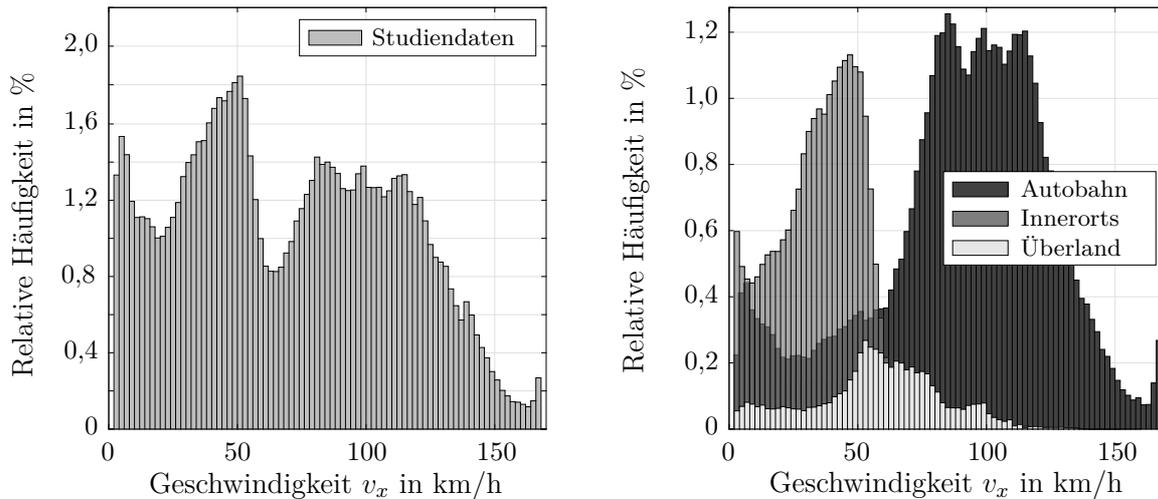
4.2 Fahrdynamische Messgrößen im Alltag

Für die Analyse der fahrdynamischen Größen im Alltag werden die für die Beschreibung der translatorischen Starrkörperbewegung wichtigen Größen $[v_x, a_x, a_y]$ untersucht. Zusätzlich werden die Fahrereingaben $\delta_H, \dot{\delta}_H$ analysiert.

4.2.1 Längsgeschwindigkeit des Versuchsträgers

Die Verteilung der Geschwindigkeit v_x des Versuchsträgers über den Studienzeitraum ist als Histogramm der Messwerte $Z_{V, \text{Studie}}$ in Abbildung 4.3a dargestellt. Der Wertebereich der gemessenen Geschwindigkeiten erstreckt sich von 0 km/h bis zu einer maximalen Geschwindigkeit von 168 km/h³⁰. Der für den Versuchsträger beobachtbare Bereich ist vollständig abgedeckt. In der Darstellung ist das Geschwindigkeitsintervall $[0, 2]$ km/h ausgeblendet, da dieses mit einem Anteil von über 10 % nicht sinnvoll dargestellt werden kann und für die fahrdynamische Betrachtung dieser Arbeit irrelevant ist. Die Verteilung der Geschwindigkeit ist multimodal, mit einer Erhöhung im Bereich bei 0 km/h, zwischen 30 km/h und 50 km/h sowie einem breiten Plateau von 80 km/h bis 120 km/h. Die erste

³⁰Im Datenblatt des Versuchsträgers aus Anhang A.3 wird eine maximale Geschwindigkeit von 164 km/h angegeben. Die gemessene maximale Geschwindigkeit beträgt 168 km/h. Die Abweichung wird über Toleranzen erklärt.



(a) Geschwindigkeitsverteilung der Studiendaten

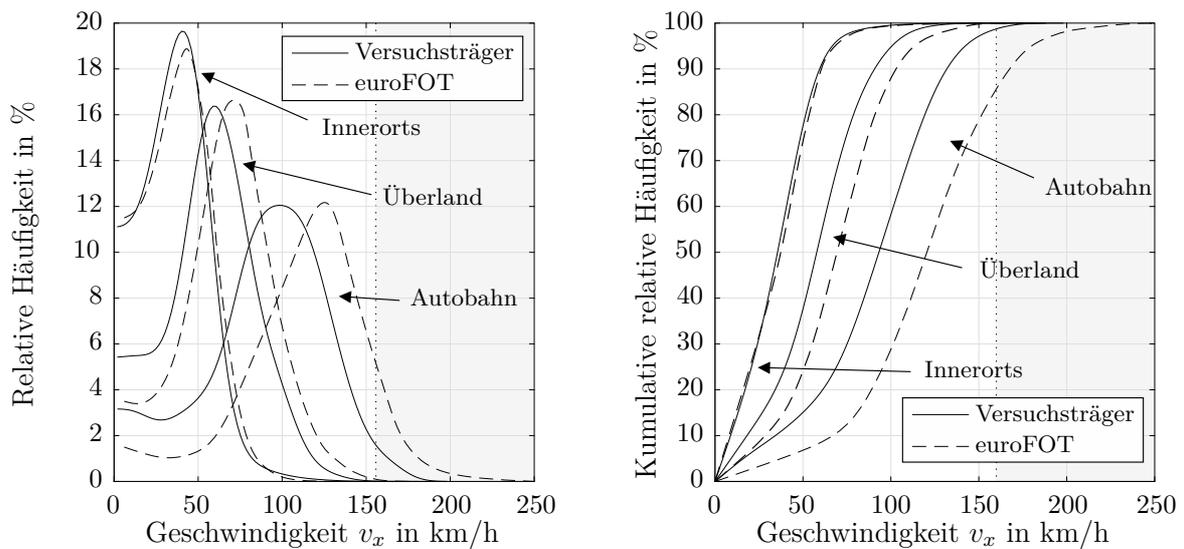
(b) Aufteilung der Geschwindigkeitsverteilung nach Straßentyp

Abbildung 4.3: Häufigkeitsverteilung der Längsgeschwindigkeit des Versuchsträgers v_x für den Studienzeitraum. Die Klassenbreite des Histogramms beträgt 2 km/h und es werden Geschwindigkeiten $v_x \geq 2$ km/h dargestellt.

Erhöhung ist durch Anfahren und Abbremsen in den Stillstand zu begründen. Die zweite Erhöhung, mit einer Konzentration der Verteilung zwischen 30 km/h und 50 km/h, ist charakteristisch für die Geschwindigkeitsverteilung von Innerortsfahrten. Das Plateau bei 80 km/h bis 120 km/h entsteht wiederum durch häufige Autofahrten. Eine Aufschlüsselung der Geschwindigkeitsverteilungen für die einzelnen Straßentypen kann Abbildung 4.3b entnommen werden. Jeder Straßentyp besitzt eine eigene charakteristische Geschwindigkeitsverteilung. Die Ausprägung der gesamten Verteilung in Abbildung 4.3a ist eine Überlagerung der Einzelverteilungen je Straßentyp und deren Gewichtung entsprechend dem Anteil im Datensatz. Für den Studiendatensatz ist bekannt, dass dessen Autobahnanteil aufgrund des Verkehrsraums erhöht ist (siehe Abschnitt 4.1.2). Ein Vergleich der Geschwindigkeitsverteilung mit anderen Studien muss aufgeteilt auf die Geschwindigkeitsverteilung je Straßentyp durchgeführt werden, um den Gewichtungsbias zu entfernen.

In Abbildung 4.4b ist ein Vergleich der Geschwindigkeitsverteilungen für die einzelnen Straßentypen des euroFOT-Datensatzes³¹ und den Fahrdaten des Versuchsträgers $Z_{V, Studie}$ dargestellt. Die Verteilungsdichtefunktionen des Versuchsträgers in Abbildung 4.4b werden mittels Kerndichtenschätzer (Bandbreite $w = 10$) aus den klassifizierten Daten (siehe Tabelle 4.1) berechnet. Die Verteilungsdichtefunktionen der euroFOT-Studie sind FABER et al. (2012, S. 24f.) entnommen. Die Verläufe beider Studien in Abbildung 4.4 je Straßentyp weisen starke Ähnlichkeit auf. Die Unterschiede bei den Geschwindigkeitsverteilungen sind für die Kategorie Autobahn am größten. Dies kann zum einen an der Limitierung

³¹Informationen zum Datensatz werden in FABER et al. (2012, S. 18) und SCHOCH et al. (2011, S. 52-66) gegeben.



(a) Vergleich der Geschwindigkeitsverteilung nach Straßentypen des Versuchsträgers und euroFOT

(b) Vergleich der kumulierten Geschwindigkeitsverteilung nach Straßentypen des Versuchsträgers und euroFOT

Abbildung 4.4: Vergleich der Geschwindigkeitsverteilung nach Straßentypen des Versuchsträgers und euroFOT aus FABER et al. (2012, S. 24f.). Die Verläufe aus FABER et al. (2012, S. 24f.) sind anhand charakteristischer Punkte nachgezeichnet und interpoliert. Ferner sind die originalen Verläufe für Geschwindigkeiten oberhalb 165 km/h abgeschnitten und werden daher geschätzt. Die Fläche in diesem Bereich ist grau hinterlegt.

der maximalen Geschwindigkeit des Versuchsträgers und zum anderen an der teilweise fehlenden Geschwindigkeitsvorgabe auf deutschen Autobahnen liegen. Die Analyse der Geschwindigkeitsverteilung nach Straßentyp zeigt große Übereinstimmungen. Die repräsentativen Verteilungen je Straßentyp werden durch den Datensatz des Versuchsträgers $Z_{V, Studie}$ ausreichend abgebildet.

4.2.2 Kombinierte Fahrzeugbeschleunigungen

In der Ebene wird die Fahrzeugbewegung maßgeblich durch die Kräfte im Reifenlatsch beeinflusst (siehe Abschnitt 2.2.1). Im Reifen treten zeitgleich Kräfte in Längs- und Querrichtung auf, die miteinander wechselwirken. Das Kraftniveau am Reifen hängt mit den Beschleunigungen a_x und a_y zusammen, sodass zunächst eine gemeinsame Betrachtung der Beschleunigungen durchgeführt wird und in einem zweiten Schritt die Größen individuell untersucht werden.

Beschleunigungspotential des Versuchsträgers

Ein einfaches und nützliches Modell zur Darstellung des Beschleunigungspotentials eines Fahrzeugs ist ein Beschleunigungsdiagramm, welches sich aus dem Kammschen Kreis ableiten lässt.

Die Bewegung des Fahrzeugs ist die Folge dynamischer Interaktionen des Fahrzeugs mit der Umgebung. Der Reifen ist ein entscheidendes Element in der Übertragung von Kräften. Sämtliche Kräfte und Momente am Reifen werden über den Reifenlatsch an das Fahrzeug übertragen. (SCHRAMM, HILLER et al., 2018, S. 145)

Die Ausprägung und Richtung der Kraft am Reifen kann durch den Fahrer beeinflusst werden. Gleichwohl ist das Kraftpotential, das dem Fahrer zur Verfügung steht, limitiert. Die übertragbare Kraft am Reifen hängt von dem Reibungskoeffizienten μ zwischen Reifen und Straße ab (RICE, 1973). Es wird angenommen, dass unabhängig von der Kombination von Lenk- und Brems- oder Antriebsmomenten am Reifen, die maximale horizontale Kraft, die der Reifen übertragen kann, durch den Reibungskoeffizienten Reifen/Straße und die Belastung des Rades begrenzt wird. Das Konzept des Kammschen Kreises bzw. Reibungskreises resultiert direkt aus diesem Zusammenhang. Es wird angenommen, dass die maximale Kraft F_{\max} , die vom Reifen übertragen werden kann, gleich der Normalkraft F_z multipliziert mit dem Reibungskoeffizienten ist. Die maximale horizontale Kraft ist richtungsunabhängig und kann durch einen Kreis dargestellt werden. Für die Kräfte am Reifen in Längs- und Querrichtung ergibt sich die Bedingung (SCHRAMM, HILLER et al., 2018, S. 167), dass

$$\sqrt{F_x^2 + F_y^2} \leq \mu F_z. \quad (4.1)$$

mit: F_x = Reifenlängskraft
 F_y = Reifenquerkraft
 F_z = Normalkraft
 μ = Reibungskoeffizient

Unter der vereinfachenden Annahme, dass sowohl Normalkraft als auch Reibungskoeffizient für die vier Reifen identisch sind, muss zwischen diesen nicht unterschieden werden. Die Folgen dieser Vereinfachung können in RICE (1973) und W. F. MILLIKEN, D. L. MILLIKEN (1995, S. 345-366) nachgeschlagen werden. Die Autoren beider Arbeiten beschreiben, dass dieses Modell trotz der getroffenen Vereinfachungen als gute Referenz dient.

Unter Berücksichtigung der Fahrzeugmasse kann das Kraftdiagramm (Kammscher Kreis) in ein Beschleunigungsdiagramm (im Englischen häufig als *G-G-Diagramm* bezeichnet) überführt werden. Unter der weiteren Annahme, dass μ konstant ist und die vertikale Beschleunigung einzig vom Fahrzeuggewicht und nicht von aerodynamischen Faktoren am Fahrzeug beeinflusst wird, wird die Beschleunigungseinhüllende zu einem Kreis mit einem Radius gleich $\mu \cdot g$. Für eine trockene Straße kann nach PACEJKA (2006) für den Reibungskoeffizienten $\mu_t \approx 0,9$ angenommen werden. (RICE, 1973)

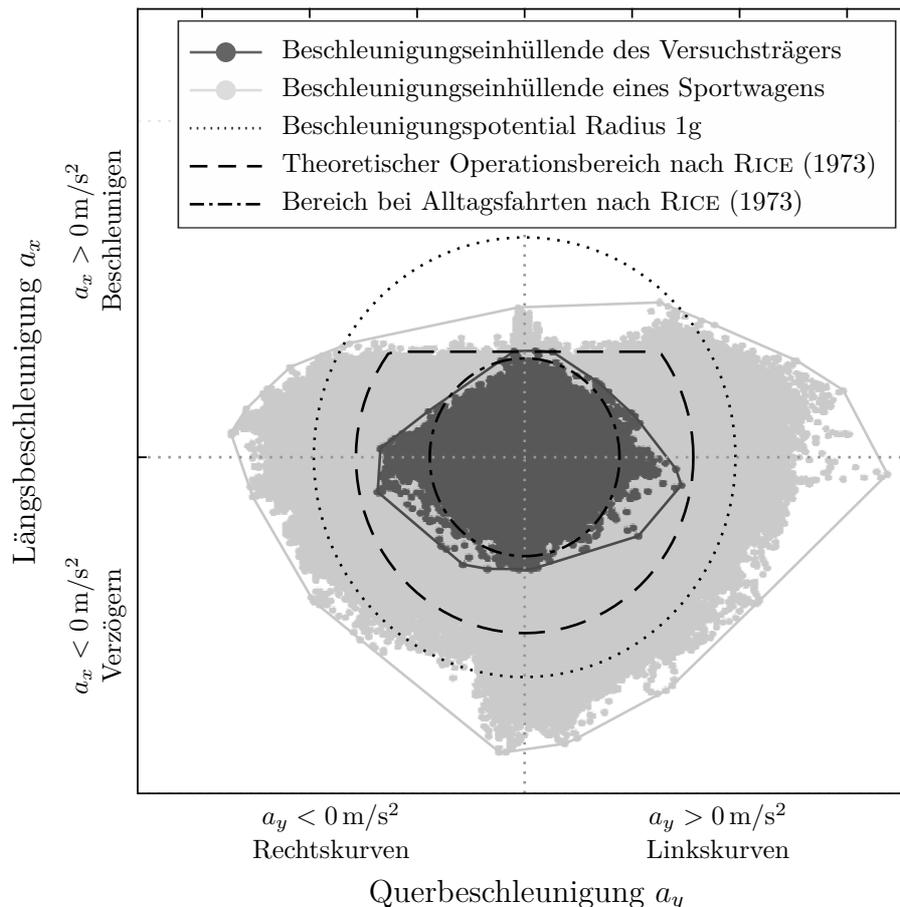


Abbildung 4.5: Diagramm translatorischer Fahrzeugbeschleunigungen des Versuchsträgers aus naturalistischen Fahrten und eines Sportwagens auf einer Rennstrecke sowie charakteristische Beschleunigungsbereiche

Weitere Einschränkungen etwa aufgrund von Lastwechseln führen dazu, dass sich dieses Potential verringert. Dies ist in dieser Arbeit mit einem Abzug von etwa 10% berücksichtigt, sodass der Radius zu $r = 0,9 \cdot 0,9 \cdot g$ wird. Aufgrund der limitierten Motorleistung bei Pkw kann das Kraftpotential des Reifens bei Beschleunigung ($a_x > 0$) nicht vollständig ausgenutzt werden und der Kreis wird durch eine horizontal verlaufende Grenze limitiert. Die maximalen Beschleunigungswerte orientieren sich an den Werten aus RICE (1973, S. 17). Nach RICE (1973) ist dies der theoretische Operationsbereich eines Fahrzeugs. Dieser ist in Abbildung 4.5 dargestellt. Alle Beschleunigungszustände $[a_x, a_y]$ des Versuchsträgers müssen innerhalb dieses Bereichs liegen.

Dieser Bereich ist theoretisch und nur für Rennfahrer von Interesse, die das Fahrzeug im Grenzbereich bewegen. In alltäglichen Fahrten wird dieser Bereich nicht ausgenutzt. In RICE (1973, S. 9) wird beschrieben, dass die meisten Fahrer nicht in der Lage oder willens sind, diesen Bereich zu nutzen. Normale Fahrer werden in alltäglichen Fahrten selten Bereiche außerhalb 50% des theoretischen Operationsbereichs nutzen. In Abbildung 4.5 ist der Bereich für Alltagsfahrten mit einer Punkt-Strich-Linie dargestellt.

Die Beschleunigungswerte des Versuchsträgers sowie deren Einhüllende sind in Abbildung 4.5 durch dunkelgraue Punkte dargestellt. Der für Alltagsfahrten erwartbare Bereich wird von den Messdaten quasi vollständig ausgefüllt. Für große Querbeschleunigungen a_y bei gleichzeitig geringer Längsbeschleunigung $|a_x| \approx 0 \text{ m/s}^2$ reichen die Messwerte sogar deutlich über den erwartbaren Bereich hinaus. Dies kann sowohl als Indiz für eine sportliche Fahrweise der Probanden gedeutet werden als auch durch die Entwicklung modernerer Fahrwerke seit Veröffentlichung der Untersuchung von RICE (1973) begründet werden. Es ist durchaus plausibel anzunehmen, dass das Sicherheitsempfinden des Fahrzeugführers für hohe Querbeschleunigungen in den zurückliegenden Jahrzehnten durch Verbesserungen am Fahrwerk und weiteren technischen Entwicklungen gesteigert werden konnte. Ferner sind die Form und die Größe des Kreises Modellannahmen, die hier nicht genauer validiert werden können.

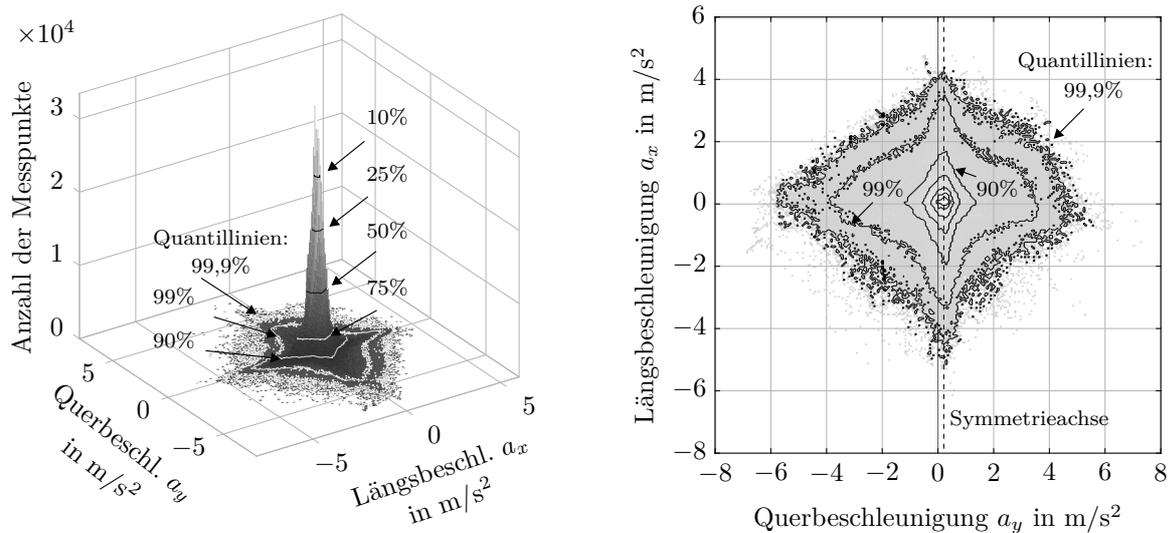
In Abbildung 4.5 sind ferner Beschleunigungswerte³² eines Sportwagens (Porsche 911 Carrera 4S) auf einer Rennstrecke abgebildet. Die gemessenen Beschleunigungen für dieses Fahrzeug reichen deutlich über den Kreis mit dem Radius $r = 1 \cdot g$ hinaus. Dies wird durch zusätzlichen Anpressdruck der Aerodynamik in Kombination mit Sportbereifung ermöglicht. Die Beschleunigungswerte liegen deutlich oberhalb dessen, was mit dem Versuchsfahrzeug physikalisch möglich ist, zeigen jedoch eindrucksvoll das mögliche Beschleunigungspotential von Pkw mit Straßenzulassung. Für die vollständige Identifikation eines solchen Fahrzeugs stößt ein naturalistisches Studiendesign an Grenzen, da solche Beschleunigungswerte im öffentlichen Straßenverkehr nicht beobachtet werden können.

Verteilung der translatorischen Beschleunigungsdaten

Innerhalb der Menge der beobachteten Beschleunigungen $Z_{V, \text{Studie}}$ ist besonders deren Verteilung von Interesse. In Abbildung 4.6 ist die Häufigkeit der Beschleunigungszustände des Versuchsträgers als multidimensionales Histogramm in zwei Ansichten dargestellt. In Abbildung 4.6a ist die Verteilung in einer Seitenansicht und in Abbildung 4.6b in einer Draufsicht der xy -Ebene dargestellt. Bereits in Abschnitt 4.2.2 wird der Bereich beschrieben, der von den Beschleunigungswerten aufgespannt wird. Als neues Merkmal wird die Verteilung der Daten innerhalb dieses Bereichs diskutiert. Die Verteilung ist näherungsweise symmetrisch für positive und negative Querbeschleunigungen, wobei die Symmetrieachse bei $a_y = 0,2 \text{ m/s}^2$ ist (siehe Abbildung 4.6b). Die Gründe hierfür liegen in einer Wankrotation des Versuchsträgers, siehe Abschnitt 3.5.

Es besteht eine sehr hohe Verteilungsdichte der Datenpunkte für kleine Beschleunigungswerte $[a_x, a_y] \approx [0 \text{ m/s}^2, 0 \text{ m/s}^2]$. Mit zunehmender Entfernung vom Ursprung nimmt die Dichte steil ab und nähert sich für Beschleunigungswerte oberhalb 4 m/s^2 einer Verteilungsdichte nahe null. Die Verteilung wird zur Beschreibung in Quantile unterteilt. Diese sind als Ringe in Abbildung 4.6 eingezeichnet und geben an, wie viel Prozent der Daten innerhalb der jeweiligen Quantilgrenze liegen. Die hohen Quantile ([75; 90; 99; 99,9] %-Quantil) besitzen die Form von Rauten mit konkaven Seiten, die kleineren Quantile ähneln

³²Bereitgestellt durch die Porsche AG



(a) Histogramm der Beschleunigungswerte $[a_x, a_y]$ als Seitenansicht

(b) Histogramm der Beschleunigungswerte $[a_x, a_y]$ als Draufsicht

Abbildung 4.6: Beschleunigungsdiagramm der Studiendaten des Versuchsträgers mit eingezeichneten Quantilllinien

Kreisen. Mithilfe der Quantilllinien lässt sich die starke Verteilungskonzentration für kleine Beschleunigungswerte quantifizieren. So nimmt die Fläche, die von der 90%-Quantillinie umschlossen wird, gegenüber der Fläche, des 99,9%-Quantils, um 90% ab.

Die These aus RICE (1973, S. 9), dass Fahrer in naturalistischen Fahrten nur äußerst selten das Beschleunigungspotential (siehe Abbildung 4.5, Radius etwa $4,5 \text{ m/s}^2$) ausreizen, wird durch die Quantilgrenzen dieser Arbeit bestätigt. Für etwa 99% der Daten trifft diese Aussage zu. Weiter kann festgehalten werden, dass 90% der Datenpunkte sogar unterhalb der Hälfte des Beschleunigungspotentials für Alltagsfahrten liegen.

In LIU, ZHU (2019, S. 3) werden die beobachteten Merkmale der Beschleunigungsverteilung des Versuchsträgers für Fahrzeuge der ChinaFOT-Studie bestätigt. Der Datensatz aus dem Zeitraum von 2014 bis 2016 umfasst 122.000 km und 3.400 Std. Fahrdaten, aufgezeichnet mit 8 baugleichen Fahrzeugen und unterschiedlichen Fahrern. Die Verteilung der Beschleunigungswerte der ChinaFOT-Daten besitzt eine sehr ähnliche Form. Es liegt eine starke Messwertkonzentration für niedrige Beschleunigungen vor. Für zunehmende Beschleunigungen fällt die Dichte der Messwerte steil ab. Das 99,9%-Quantil liegt ähnlich wie bei dieser Arbeit innerhalb eines Radius von $4,5 \text{ m/s}^2$ und stellt die äußere Grenze dar. Beide Datensätze zeigen hohe Ähnlichkeit hinsichtlich der Verteilung von Beschleunigungswerten.

Insbesondere bei der Diskussion um die übertragbaren Reifenkräfte und die damit verbundenen Fahrzeugbeschleunigungen sind die Umgebungsbedingungen von Interesse. Die maximale Reifenkraft hängt vom Reibungskoeffizienten μ zwischen Reifen und Straße ab.

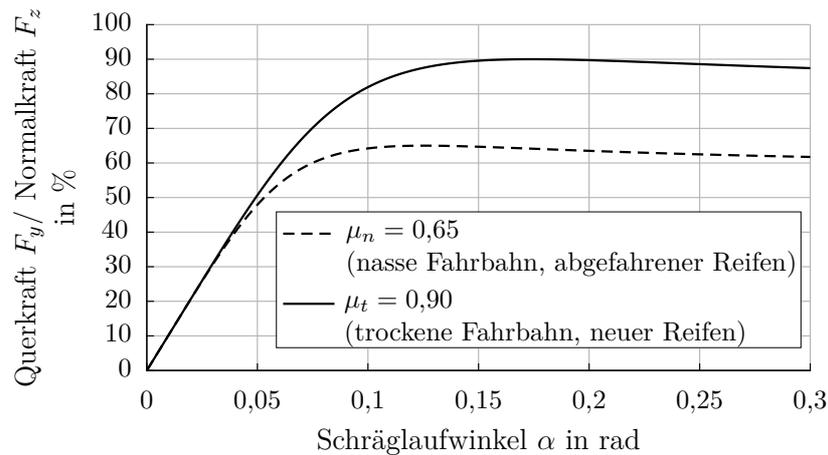


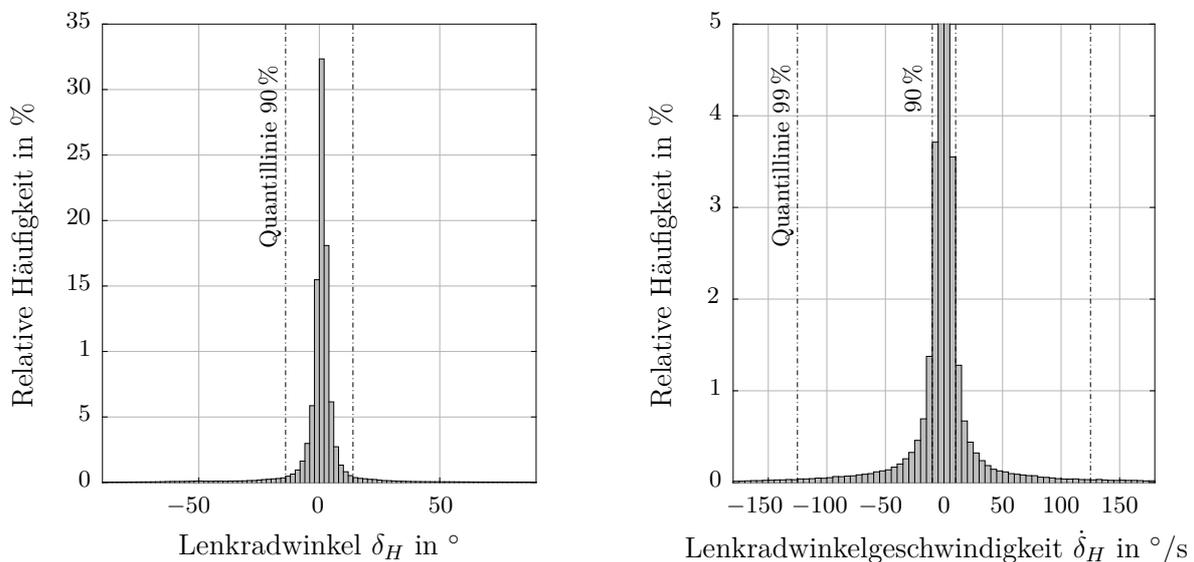
Abbildung 4.7: Charakteristische Reifenkennlinie der Querkraft für unterschiedliche Reibungskoeffizienten aus REICHERTS, HESSE et al. (2021)

Er variiert für verschiedene Fahrbahnoberflächen und wird auch von Wetterbedingungen (Nässe, Schnee) beeinflusst. Da diese Bedingungen mit der vorhandenen Sensorik nicht erfasst werden können, können sie nicht weiter analysiert oder als zusätzliche Eingänge für die Identifikation verwendet werden. Mithilfe des etablierten Reifenmodells von PACEJKA (2006) (Magic Formula) werden der Einfluss des Reibungskoeffizienten μ auf die übertragbare Reifenkraft und mögliche Einflüsse auf diese Studie abgeschätzt. Hierfür werden zwei sehr unterschiedliche Reifen-Fahrbahn-Kontakte verglichen, um zu zeigen, wie die Daten durch diesen Aspekt beeinflusst werden könnten. Es wird ein Reibungskoeffizient von $\mu_t = 0,9$ für einen neuen Reifen auf einer trockeneren Straße und $\mu_n = 0,65$ für einen abgefahrenen Reifen auf nasser Straße angenommen (in Anlehnung an PACEJKA (2006, S. 44-45)³³). In Abbildung 4.7 sind die charakteristischen Reifenkennlinien beider Varianten des Reibungskoeffizienten dargestellt. Für den Alltagsbetrieb ist der Quotient aus $\frac{a_y}{g} \approx \frac{F_y}{F_z} < 0,4$. Dies geht aus der Analyse der Beschleunigungswerte aus Abbildung 4.6b hervor. Das Verhalten des Reifens ist für verschiedene Straßenbedingungen für diesen Dynamikbereich (kleiner $a_y < 4 \text{ m/s}^2$) annähernd identisch. Saisonale Einflüsse auf den Reibungskoeffizienten etwa durch Wetterbedingungen können somit nicht erkannt werden. Diese Erkenntnis stellt eine Einschränkung des Ansatzes dar. NDS sind nicht oder nur schlecht geeignet, um den Einfluss des Reibungskoeffizienten auf die Fahrzeugdynamik zu erkennen, da der benötigte Bereich der Fahrzeugdynamik nicht richtig angeregt wird. Gleichzeitig ist der auf die Messung wirkende Einfluss des Reibungskoeffizienten für die Daten der Studie minimal und kann vernachlässigt werden (REICHERTS, HESSE et al., 2021).

³³Gewählte Modellparameter: $c_1 = 60000 \text{ N/rad}$, $c_2 = 4000 \text{ N/rad}$, $F_z = 5500 \text{ N}$, $C = 1,3$, $E = -2$

4.2.3 Lenkradwinkel und Lenkradwinkelgeschwindigkeit

Der Lenkradwinkel δ_H und die Lenkradwinkelgeschwindigkeit $\dot{\delta}_H$ werden direkt vom Fahrer gestellt. Sie beeinflussen das querdynamische Verhalten des Versuchsträgers maßgeblich. Die Verteilung beider Größen für die Studiendaten ist in Abbildung 4.8 dargestellt (Stillstände $v_x = 0$ km/h sind von den Verteilungen ausgeschlossen). Die Verteilungen des Lenkradwinkels δ_H und dessen Geschwindigkeit $\dot{\delta}_H$ haben für Werte nahe 0° bzw. $0^\circ/\text{s}$ sehr hohe Verteilungsdichten. Diese fallen für im Betrag steigende Werte steil ab. Die Ränder der Verteilungen werden aufgrund geringer Verteilungsdichten nicht vollständig dargestellt. Für den Lenkradwinkel liegen die maximalen Werte bei $\delta_H = [-475^\circ; 475^\circ]$. Die Darstellung der Verteilung der Lenkradwinkelgeschwindigkeit in Abbildung 4.8b ist auf $|\dot{\delta}_H| \leq 180^\circ/\text{s}$ begrenzt. Zusätzlich wird der Wert der relativen Häufigkeit für kleine $\dot{\delta}_H$ in Abbildung 4.8b aus Skalierungsgründen nicht vollständig dargestellt.



(a) Verteilung des Lenkradwinkels der Studiendaten

(b) Verteilung der Lenkradwinkelgeschwindigkeit der Studiendaten

Abbildung 4.8: Verteilung des Lenkradwinkels δ_H sowie der Lenkradwinkelgeschwindigkeit $\dot{\delta}_H$ der Studiendaten

Für die Verteilungen von δ_H und $\dot{\delta}_H$ werden die Quantile³⁴ berechnet. Für den Lenkradwinkel δ_H sind das 50/75/90/99%-Quantil $2,1/4,5/14,0^\circ$ bzw. $197,7^\circ$. Für die Lenkradwinkelgeschwindigkeit $\dot{\delta}_H$ sind das 50/75/90/99%-Quantil $1,1/3,2/10,0^\circ/\text{s}$ bzw. $125,1^\circ/\text{s}$. Die Hälfte aller Messwerte des Lenkradwinkels δ_H liegen zwischen $\pm 2,1^\circ$ und etwa 90% der Messwerte sind im Betrag kleiner als $14,0^\circ$. Für einen Großteil der Fahrten wird der mögliche Lenkwinkelbereich nicht ausgeschöpft und die querdynamische Anregung ist entsprechend gering.

³⁴Die berechneten Quantile beziehen sich auf den Betrag der Messwerte und sind daher symmetrisch für positive und negative Messwerte.

Aus den Manövern für querdynamische Untersuchungen aus Tabelle 2.2 ist bekannt, dass neben dem Lenkwinkel δ_H vor allem dessen Änderungsgeschwindigkeit $\dot{\delta}_H$ als Systemanregung relevant ist. Speziell für die Anregung des Übergangsverhaltens (schnelle Richtungswechsel) sind hohe Lenkwinkelgeschwindigkeiten notwendig. Exemplarisch werden die Manöver *Lenkwinkelsprung* und das *Sinuslenken* aus der Manövernorm ISO 7401³⁵ für transientes querdynamisches Verhalten ausgewählt und analysiert.

- **Lenkwinkelsprung**
Für einen Lenkradwinkelsprung wird die Lenkradstellung möglichst schnell von einer Ausgangsstellung zu einer Zielstellung geändert. Ein Lenkwinkelsprung von 90° verlangt unter Einhaltung der zeitlichen Vorgaben aus ISO 7401 eine mittlere Lenkradwinkelgeschwindigkeit von $480^\circ/\text{s}$.
- **Sinuslenken**
Beim Sinuslenken wird eine vollständige Schwingung mit 0,5 Hz oder 1 Hz gefordert. Hieraus folgt eine Lenkradwinkeländerung von $|\dot{\delta}_{H,max}| \geq 180^\circ/\text{s}$.

Die Verteilung der Lenkradwinkelgeschwindigkeit $\dot{\delta}_H$ aus Abbildung 4.8b zeigt, dass für 99% der Daten die Lenkradwinkelgeschwindigkeit $\dot{\delta}_H$ kleiner als $125^\circ/\text{s}$ ist. Lenkradwinkelgeschwindigkeiten, die zur Anregung von transientem querdynamischem Verhalten notwendig sind, sind in alltäglichen Fahrten sehr selten. Dies stellt eine Limitierung im Studiendesign dar.

4.3 Statistische Analyse des Datensatzes auf Adäquanz

Die Untersuchung des Studiendatensatzes auf Adäquanz kann sich auf unterschiedliche Eigenschaften des Datensatzes beziehen. Im vorherigen Abschnitt wird gezeigt, dass die in naturalistischen Fahrten zu erwartenden Merkmalsausprägungen der Messgrößen aufgezeichnet wurden und dass die Verteilungen der Messgrößen denen von repräsentativen Studien folgen. In Abschnitt 3.1.2 wird die These formuliert, dass der erwartete Informationszugewinn mit zunehmender Studiendauer abnimmt. Bereits LIU, ZHU et al. (2018), LIU, ZHU (2019) und WANG et al. (2017) haben für naturalistische Fahrten eine ähnliche These formuliert und untersucht, wie viele Daten in einer solchen Studie sinnvollerweise aufgezeichnet werden (siehe Abschnitt 2.5.2). Es wird der Zeitpunkt gesucht, an dem das Hinzufügen weiterer Daten zum bestehenden Datensatz die Verteilung und somit den Informationsgehalt der Daten nur noch minimal ändert. Sobald weitere Messungen den Informationsgehalt nicht mehr wesentlich ändern, kann die Messung beendet werden. Der Datensatz hat eine adäquate Größe erreicht.

³⁵Vollständige Bezeichnung: ISO 7401 :Road vehicles - Lateral transient response test methods - Open-loop test methods

4.3.1 Ablauf der statistischen Analyse

Das schematische Vorgehen der Analyse der Studiendaten ist in Abbildung 4.9 dargestellt. Die Daten der Fahrstudie liegen entsprechend der Reihenfolge der Fahrtenaufzeichnung vor. Jede Fahrt wiederum besteht aus einem Fahrdatenvektor $\mathbf{z}(t_i)$, welcher sich aus m Messgrößen zusammensetzt. Die Fahrten werden in eine neue Reihenfolge sortiert (siehe Abbildung 4.9 bei 2). Dieser Schritt wird zehnfach durchgeführt, sodass zehn Sequenzen \mathbf{Q}^κ für $\kappa \in [1, \dots, 10]$ entstehen. Jede Sequenz \mathbf{Q}^κ besteht aus allen Fahrten der Studie in der sequenzeigenen Reihenfolge. Die Fahrten selbst bleiben unverändert. Die unterschiedlichen Sequenzen werden genutzt, um zu untersuchen, welchen Einfluss die Reihenfolge der Fahrten auf das Kriterium der Adäquanz hat. Die Sequenzen setzen sich aus $m \times N$ Elementen zusammen, wobei N die Summe der Datenpunkte über alle Messfahrten ist und m die Anzahl der Messgrößen. Aus den Sequenzen werden die Untersequenzen der zu untersuchenden Messgrößen $\mathbf{Q}_{\text{uni/bi}}^\kappa$ gebildet. Für die vorliegende Arbeit werden die univariate Verteilung der Messgröße v_x und die bivariate Verteilung der Messgrößen $[a_x, a_y]^T$ untersucht. Die Kullback-Leibler-Divergenz wird für zunehmend große Datenpakete einer Sequenz untersucht (siehe Abbildung 4.9 bei 3). Die Sequenz \mathbf{Q}^κ wird in Datenpakete der Länge p unterteilt. Zunächst wird das erste Datenpaket der Sequenz verwendet, um eine Verteilungsdichtefunktion $\hat{f}_1([\mathbf{Q}]_{k=1}^p)$ zu berechnen. In weiteren Schritten werden dann weitere Datenpakete der Länge p hinzugefügt und erneut die Dichtefunktion ermittelt. Dies kann iterativ wiederholt werden und es ergeben sich damit die Verteilungsdichtefunktionen $\hat{f}_q([\mathbf{Q}]^{qp})$. Hierbei ist q eine Laufvariable, die anzeigt, wie viele einzelne Pakete der Länge p zur aktuell ausgewerteten Dichtefunktion gehören. Zuletzt ergibt sich die Betrachtung der gesamten Sequenz \mathbf{Q}^κ . Als Verteilungsdichtefunktion wird ein Kerndichtenschätzer mit Gaußkern verwendet (siehe Abschnitt 2.5.2). Eine geeignete Bandbreite kann mit Silverman's Rule of Thumb (siehe Gleichung 2.25) bestimmt werden. Eine Untersuchung, dass die Anwendung der Gleichung 2.25 für die Datenbasis zulässig ist, kann Anhang A.4.1 entnommen werden. Aus den Verteilungsdichten \hat{f}_{q+1} und \hat{f}_q kann die Kullback-Leibler-Divergenz $D_{\text{KL}}(\hat{f}_{q+1}; \hat{f}_q)$ (Gleichung 2.11) berechnet werden. Gemäß der Hypothese werden der Informationszuwachs und somit die Divergenz mit zunehmender Datenmenge abnehmen. Eine monoton fallende Folge von D_{KL} ist für reale Fahrdaten allerdings nicht zu erwarten (siehe Abschnitt 4.4). Für die Analyse wird das in LIU, ZHU (2019) vorgestellte Kriterium verwendet, das Schwankungen im Verlauf berücksichtigt. Gesucht wird das kleinste Γ , für das gilt:

$$\Gamma = \min_{\hat{\Gamma}} \{ \hat{\Gamma} \leq q \cdot p \leq N, D_{\text{KL}}(f_{q+1}(\mathbf{Q}); f_q(\mathbf{Q})) < \xi \} \quad (4.2)$$

- mit: D_{KL} = Kullback-Leibler-Divergenz
 \mathbf{Q} = Sequenz aus pq bzw. $p(q + 1)$ Elementen
 f = Verteilungsdichtefunktion
 p = Datenpaketgröße
 q = Laufvariable
 ξ = Abbruchkriterium

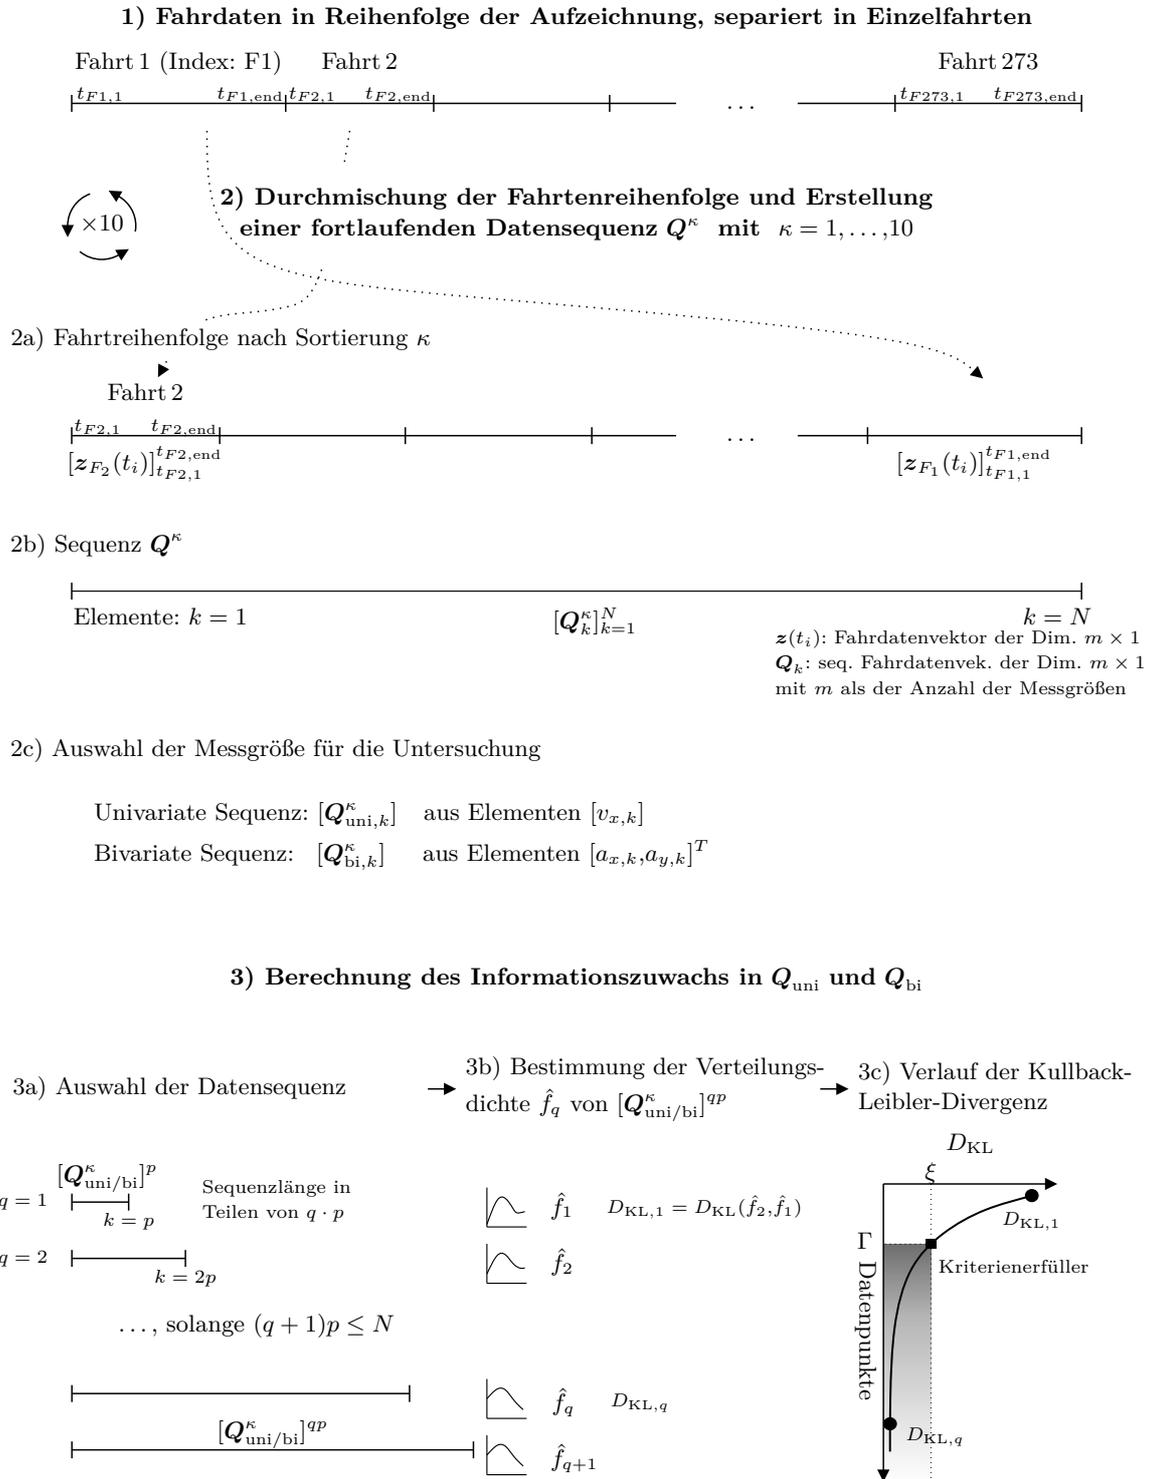


Abbildung 4.9: Untersuchung der Fahrdaten auf Adäquanz. Darstellung der einzelnen Arbeitsschritte bis zur Anwendung der Kullback-Leibler-Divergenz

Designparameter

Der Verlauf der Kullback-Leibler-Divergenz sowie das Abbruchkriterium Γ aus Gleichung 4.2 sind von verschiedenen Einflussgrößen abhängig. Eine allgemeine Handlungsempfehlung bzgl. der Parameterauswahl ist nicht bekannt, sodass verschiedene Parameterkombinationen verwendet und deren Einfluss auf den Verlauf untersucht werden.

- **Fahrdynamische Größen:**

Für die Bewertung der Adäquanz hinsichtlich der Dynamik des Versuchsträgers werden die für die Bewegung des Fahrzeugs in der Ebene vorhandenen Messgrößen $[v_x, a_x, a_y]$ verwendet. Die Verteilung der Geschwindigkeit wird als univariate Verteilung untersucht. Die Beschleunigungen werden aufgrund ihrer starken Wechselwirkung (siehe Abschnitt 4.2.2) als bivariate Verteilung betrachtet. Die Analyse weiterer Messgrößen³⁶ oder höherdimensionaler Verteilungen (trivariat oder höher) sind durchaus denkbar, lassen jedoch den Rechenaufwand stark ansteigen.

- **Reihenfolge der Daten:**

Die Robustheit der Untersuchungsmethode wird mit unterschiedlichen Sequenzreihenfolgen \mathbf{Q}^κ für $\kappa \in [1, \dots, 10]$ untersucht. Wird die Hypothese aus Abschnitt 3.1.2 bestätigt, nimmt der Informationszugewinn für alle Sequenzen ab. Der Informationsinhalt der verschiedenen Sequenzen wird sich mit steigender Datenmenge angleichen.

- **Einfluss der Datenpaketgröße p :**

Die Wahl der Datenpaketgröße p orientiert sich an den Vorgaben aus LIU, ZHU et al. (2018), LIU, ZHU (2019) und WANG et al. (2017). Die Untersuchung wird mit $p = 9 \cdot 10^3$ bzw. $36 \cdot 10^3$ (entspricht 15 bzw. 60 min) durchgeführt und die Auswirkungen der Datenpaketgröße p auf die Kullback-Leibler-Divergenz D_{KL} dokumentiert.

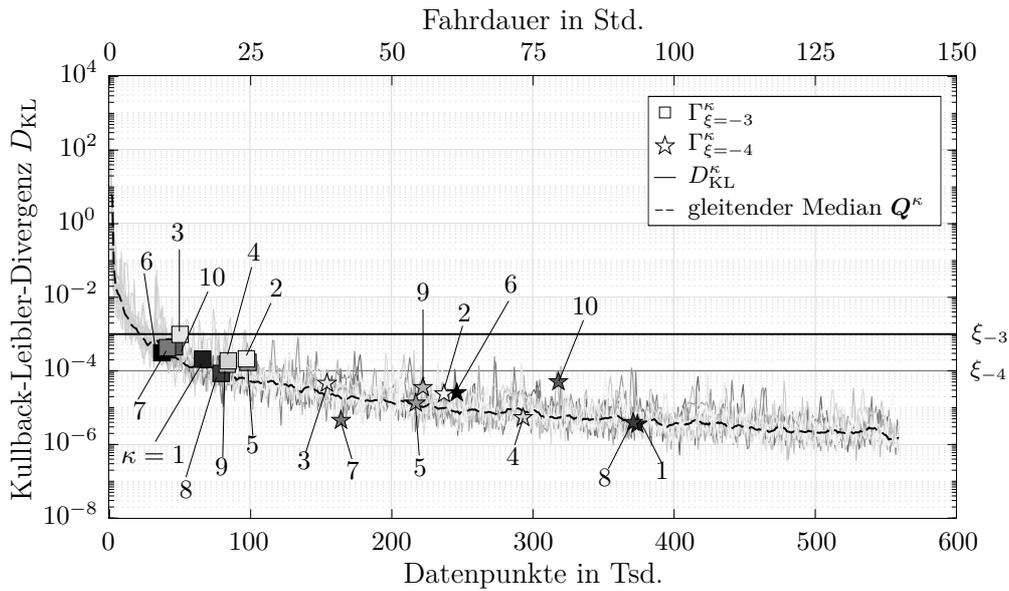
- **Abbruchkriterium ξ :**

Zur Erfüllung des Abbruchkriteriums aus Gleichung 4.2 muss der Grenzwert ξ (dauerhaft) unterschritten werden. In LIU, ZHU et al. (2018), LIU, ZHU (2019) und WANG et al. (2017) werden für ξ Werte von 10^{-3} und 10^{-4} genutzt. Der Grenzwert ξ ist eine empirisch gewählte mathematische Kennzahl ohne physikalische Bindung.

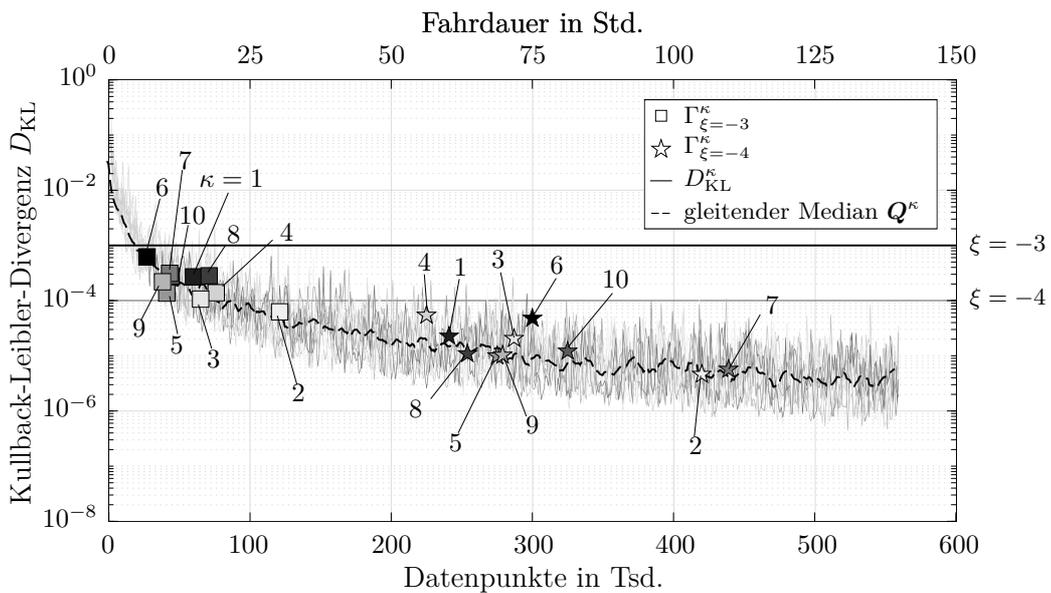
4.3.2 Auswertung der Kullback-Leibler-Divergenz

In Abbildung 4.10 sind die Verläufe der Kullback-Leibler-Divergenz für die zehn Sequenzen \mathbf{Q}^κ der uni- und bivariaten Verteilung dargestellt. Als Datenpaketgröße wird $p = 9 \cdot 10^3$ gewählt. Die Darstellung der Verläufe für eine Paketgröße von $p = 36 \cdot 10^3$ ist im Anhang A.4.2 in Abbildung A.7 dargestellt. Die Kullback-Leibler-Divergenz ist logarithmisch über der Datenmenge bzw. Fahrdauer aufgetragen. Für jede Sequenz wird die Fahrdauer Γ ,

³⁶Auf die Darstellung der Analyse der Kullback-Leibler-Divergenz für den Lenkradwinkel δ_H wird verzichtet, da diese keine weiteren Erkenntnisse beigesteuert hat.



(a) Univariate Verteilung: Verlauf der Kullback-Leibler-Divergenz für die univariate Verteilung der Längsgeschwindigkeit v_x für eine Datenpaketgröße $p = 9 \cdot 10^3$



(b) Bivariate Verteilung: Verlauf der Kullback-Leibler-Divergenz für die bivariate Verteilung der Beschleunigungen $[a_x, a_y]$ für eine Datenpaketgröße $p = 9 \cdot 10^3$

Abbildung 4.10: Auswertung der Kullback-Leibler-Divergenz für die verschiedenen Sequenzen Q^κ der Daten der Fahrstudie

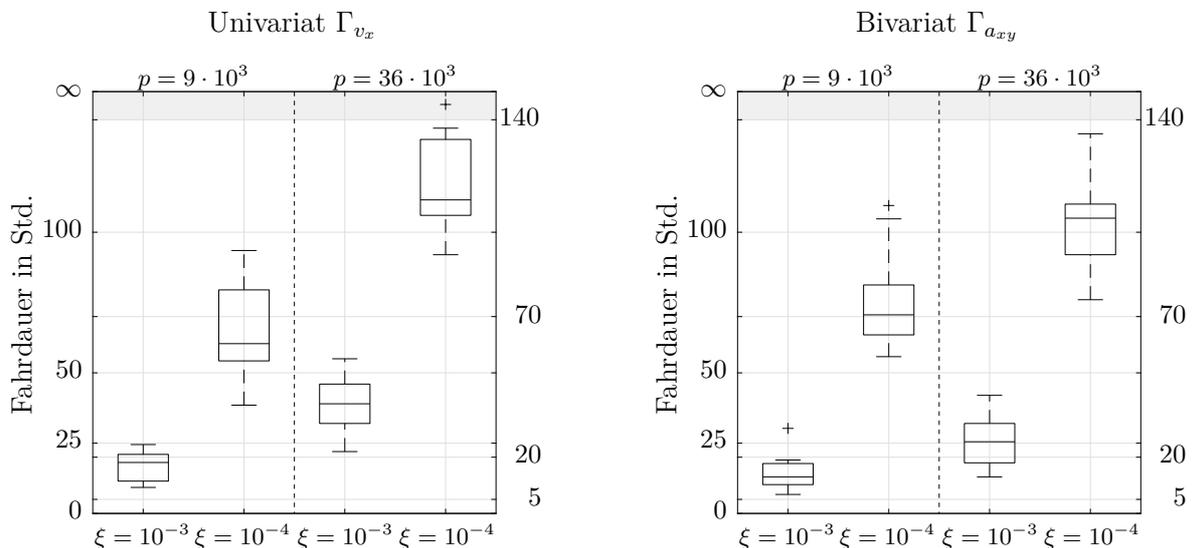
zu der das Abbruchkriterium aus Gleichung 4.2 erfüllt wird, hervorgehoben. Für einen Grenzwert $\xi = 10^{-3}$ werden Quadrate eingezeichnet. Für das Erreichen eines Grenzwertes $\xi = 10^{-4}$ werden Sterne verwendet. Die an den Symbolen angeheftete Ziffer steht für die

Sequenznummer κ . Die gestrichelte Linie ist der gleitende Mittelwert des Medians der Sequenzen $Q^{1:10}$.

Die Divergenzverläufe der beiden Verteilungen (Abbildung 4.10a und 4.10b) ähneln einander stark. Aufgrund der physikalischen Kopplung zwischen der Geschwindigkeit v_x und der Beschleunigung a_x können die beiden Verteilungen und somit auch der Informationszugewinn nicht als vollständig unabhängig betrachtet werden. Für eine geringe Datenmenge liegen die Divergenz D_{KL} bei Werten der Größenordnung 10^2 bis 10^0 . Zu Beginn ist ein sehr starker Abfall der Divergenz zu beobachten. Dieser Bereich erstreckt sich bis 25 Std. Fahrdaten, was etwa 100.000 Messpunkten entspricht. Für die maximale Sequenzlänge von 140 Std. liegen die Divergenzwerte bei etwa 10^{-6} .

Die Verläufe der einzelnen Sequenzen sind nicht monoton fallend, sondern weisen hohe Schwankungen auf. Zum Erfüllen des Abbruchkriteriums muss daher der Grenzwert ξ nicht einmalig, sondern dauerhaft unterschritten werden. Hierbei sind die Schwankungen im Verlauf der bivariaten Verteilung größer als bei der univariaten. Durch die Darstellung des gleitenden Medians aus allen Sequenzen kann der Informationszugewinn über einen Zeitraum dargestellt und abgelesen werden. Die Linie des gleitenden Medians flacht für größere Datenmengen ab und die Hypothese aus Abschnitt 3.1.2 wird bestätigt. Der Informationszuwachs wird mit zunehmender Studiendauer geringer.

Die Studiendauer zum Erreichen des Abbruchkriteriums Γ wird für die 10 Sequenzen und unterschiedlichen Parameterkonfigurationen berechnet. Die Verteilung von Γ wird in Abbildung 4.11 in Boxplots dargestellt. Es werden der Einfluss des Grenzwertes ξ und der Datenpaketgröße p auf die Fahrdauer Γ sowohl für die univariate und die bivariate Ver-



(a) Verteilung der Kriterienerfüller für die univariate Verteilung

(b) Verteilung der Kriterienerfüller für die bivariate Verteilung

Abbildung 4.11: Erreichen des Abbruchkriteriums für verschiedene Sequenzen derselben Messgröße für unterschiedliche Parameterkonfigurationen

teilung abgebildet. Eine Zusammenfassung zur Darstellung von Stichprobenverteilungen mit Boxplots kann Abschnitt 2.5.2 entnommen werden.

Die Verteilungen in Abbildung 4.11 weisen große Unterschiede für verschiedene Konfigurationen auf. Grundsätzlich lässt sich erkennen, je kleiner das Abbruchkriterium ξ gewählt wird, desto später wird Γ erreicht. Je größer die Datenmenge p gewählt wird, desto später wird Γ erreicht. Beide Zusammenhänge erscheinen intuitiv und logisch. Ferner nimmt die Interquartils- und Whiskerlänge (Streuung je Boxplot) für das kleiner werdende Abbruchkriterium ξ stark zu. Offensichtlich wird Γ nicht ausschließlich über die Datenbasis, sondern auch ganz maßgeblich über die Parameterkonfiguration beeinflusst. Dies ist insofern kritisch zu bewerten, als dass die Parameterwahl nicht auf physikalischen Zusammenhängen fußt, sondern vom Anwender beliebig festgelegt werden kann.

Der Reiz eines mathematischen Kriteriums zur Bestimmung eines festen Zeitpunktes, an dem Adäquanz erreicht wird, ist offensichtlich. Für den vorliegenden Datensatz erscheint die Definition eines absoluten Kriteriums ohne Bezug zum Identifikationsvorhaben allerdings nicht plausibel. In realen Daten ist ein solcher Zeitpunkt rein aus den Daten heraus nicht zu definieren. Vielmehr ist es wichtig, die statistischen Erkenntnisse mit physikalischem Wissen zu kombinieren, um eine Aussage zur Adäquanz tätigen zu können.

Alle 10 Divergenzverläufe in Abbildung 4.10 zeigen sehr ähnliche Verläufe und flachen nach etwas mehr als 20 Std. deutlich ab. Der Informationszugewinn nimmt mit zunehmender Studiendauer ab. Dies schließt durchaus ein, dass der Informationszugewinn nie vollständig endet und seltene Fahrereignisse neue Informationen liefern können. Die Interpretation des Verlaufs der KLD aus Abbildung 4.10 ist, dass in den ersten 20 Std. der Fahrstudie der Informationszugewinn sehr groß ist. Für die zweite Hälfte der Studie, etwa ab 70 Std., ist der Informationszugewinn nur noch minimal.

Mit dem zusätzlichen Wissen aus den Abschnitten 4.1 und 4.2, dass die Beobachtungen der Fahrstudie mit denen anderer Studien übereinstimmen und dass der Studiendatensatz $Z_{V,Studie}$ aus 140 Std. die erwartete Dynamik vollständig abbildet, kann gefolgert werden, dass die Daten der gesamten Studien adäquat sind. Die Ergebnisse der Modellbildung können die These der Adäquanz stützen und zeigen, welche Auswirkung der Datenumfang und der Informationszuwachs auf die Modellbildung haben (siehe Abschnitt 5.3).

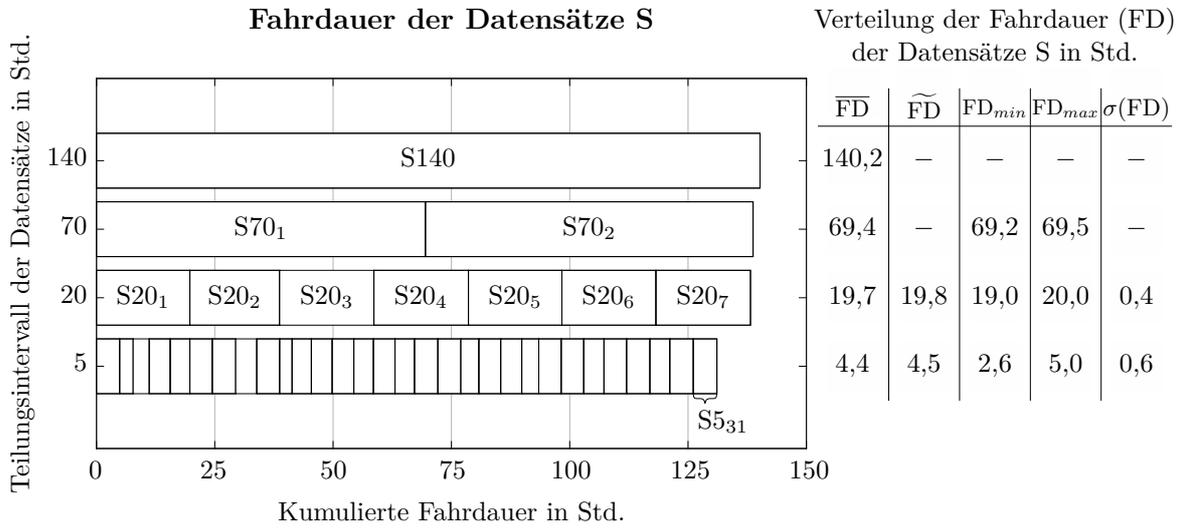
4.4 Teilung Studiendaten in Subdatensätze gleicher Fahrdauer

Über die benötigte Datenmenge für eine valide Modellbildung der Fahrdynamik basierend auf naturalistischen Fahrdaten ist wenig bekannt. Eine Untersuchung mit einem vergleichbaren Datensatz wurde in der Literatur nicht gefunden. Neben der erreichbaren Modellgenauigkeit soll daher auch die benötigte Datenmenge und der Zusammenhang zwischen beiden untersucht werden. Es ist wünschenswert, bereits mit kürzer angelegten Studien (unterhalb 12 Monaten) valide Erkenntnisse zu erzielen.

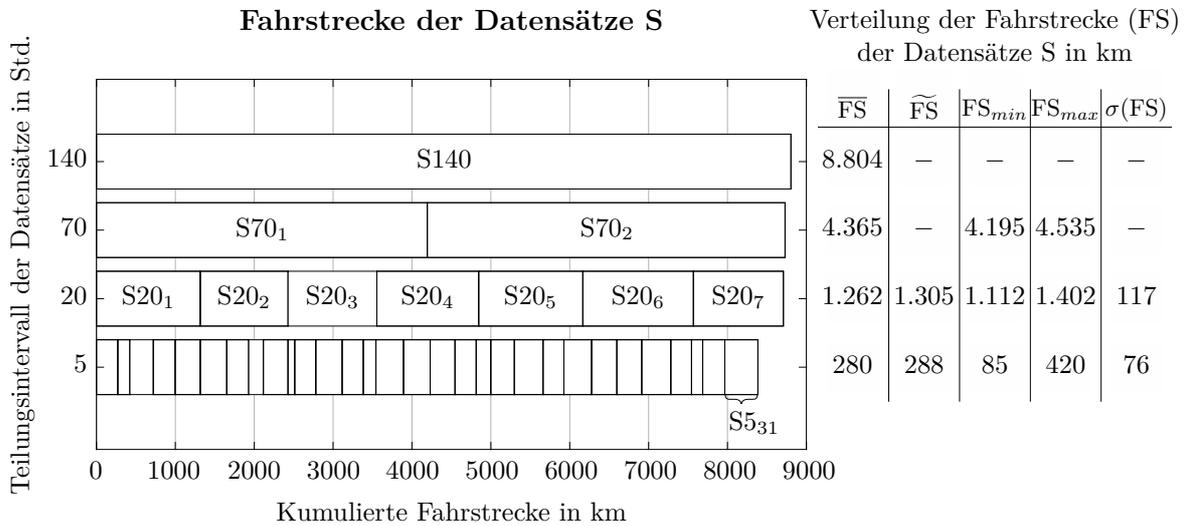
Die Modellbildung in Kapitel 5 wird an Datensätzen unterschiedlicher Größe durchgeführt. Hierfür wird der Datensatz in Subdatensätze zerteilt. Die Sequenz Q^1 , die aus allen Fahrten der Studie besteht, wird ausgewählt und in Subdatensätze näherungsweise gleicher Größe zerteilt (siehe Abbildung 4.12).

Die Fahrten in Sequenz Q^1 sind in zufälliger Reihenfolge sortiert, sodass jahreszeitbedingte Umwelteinflüsse oder Einflüsse durch Alterung und Verschleiß in den Subdatensätzen möglichst gleich verteilt sind. Q^1 wird in 31 unabhängige Sätze mit je 5 Std. Fahrdaten, 7 Sätze mit 20 Std., 2 Sätze mit 70 Std. und einen Satz, der alle 273 Fahrten enthält, untergliedert. Die Subdatensätze werden mit S5, S20, S70 bzw. S140 bezeichnet. Die Subdatensätze bestehen ausschließlich aus kompletten Fahrten und sind daher nicht exakt gleich groß. Die genannten Satzgrößen sind obere Grenzen, sodass die tatsächlichen Sätze kleiner-gleich 5, 20 oder 70 Std. sind.

In Abbildung 4.12 ist die Teilung visualisiert. In der oberen Abbildung 4.12a ist die Fahrdauer abgebildet und in Abbildung 4.12b die zugehörige Fahrstrecke. In den angrenzenden Tabellen innerhalb der Abbildung sind die Kennzahlen der Datensätze aufgelistet. Es werden der durchschnittliche Wert \overline{FD} , der Median \widetilde{FD} , das Minimum FD_{min} , das Maximum FD_{max} sowie die Standardabweichung angegeben. Relative Schwankungen sind in den kleineren Datensätzen erwartungsgemäß deutlich größer. Je größer die Datensätze werden, desto ähnlicher werden sich diese.



(a) Fahrdauer der einzelnen Datensätze S gleicher Fahrdauer



(b) Fahrstrecke der einzelnen Datensätze S gleicher Fahrdauer

Abbildung 4.12: Aufteilung der Sequenz Q^1 in Subdatensätze S gleicher Fahrdauer

Modellbildung der Querdynamik

In diesem Kapitel wird die Modellbildung und Identifikation der Querdynamik des Versuchsträgers für die Studiendaten vorgestellt. Für die Modellbildung werden jeweils ein Ansatz der theoretischen und ein Ansatz der experimentellen Modellbildung ausgewählt und das Vorgehen für diese aufgezeigt. Für die Klasse der theoretischen Modelle wird ein Lineares Einspurmodell gewählt. Für die Klasse der experimentellen Modelle werden Künstliche Neuronale Netze genutzt. Ein Ansatz, der die Identifikationsergebnisse durch die Gewichtung des Datensatzes verbessern kann, wird präsentiert. Hierbei werden die Fahrten in Segmente unterteilt und aus diesen ein balancierter Datensatz erzeugt. Bei der Identifikation werden Datensätze unterschiedlicher Größe eingesetzt, um den Einfluss der Datenmenge auf die Modellgenauigkeit zu untersuchen.

5.1 Systemgrenzen des Modells

Die Fahrzeugquerdynamik als Teilgebiet der Fahrzeugdynamik wird sowohl von Fahrereingaben als auch von Umwelteinflüssen beeinflusst (siehe Abschnitt 2.2.1). Der Fahrzeugführer kann über die Bedienelemente Gaspedal, Bremse und Lenkrad das Fahrzeug führen. Der Signalfluss, ausgehend von den Fahrereingaben hin zu einer querdynamischen Reaktion des Fahrzeugs, ist in Abbildung 5.1 dargestellt. Der hier dargestellte Signalfluss stellt eine Vereinfachung und zentrale Annahme in der Modellbildung für diese Arbeit dar. Es wird angenommen, dass die Querdynamik vollständig entkoppelt von der Vertikaldynamik

betrachtet werden kann und dass keine Rückkopplung zur Längsdynamik³⁷ besteht (die Aktuierung einzelner Räder wird vernachlässigt). Die Querdynamik hängt folglich einzig vom Lenkradwinkel und der Fahrzeuggeschwindigkeit ab. Alle durch diese Vereinfachung bewirkten Ungenauigkeiten werden in einem Störungsterm ϵ_{QD} zusammengefasst, dessen Größe zunächst unbekannt ist. Diese Annahmen sind zweckmäßig und ermöglichen eine Modellierung mit deutlich reduzierter Komplexität (HEISSING et al., 2011, S. 37). Eine detaillierte Betrachtung und Diskussion der getroffenen Vereinfachungen für die dargestellte Entkopplung wird in Abschnitt 5.3 gegeben. Als Ausgang des Modells der Querdynamik wird die Querbeschleunigung a_y gewählt. Die Modellgrenzen sind so gewählt, dass Lenkradwinkel δ_H und Fahrzeuglängsgeschwindigkeit v_x als Eingänge und die Querbeschleunigung a_y als Ausgang definiert werden. Diese Größen werden messtechnisch erfasst. Ferner wirken auf das System unbekannte Störgrößen ϵ_{QD} . Der Systemausgang a_y

$$a_y = f(\delta_H, v_x, \epsilon_{\text{QD}}) \quad (5.1)$$

kann als Funktion des Lenkradwinkels δ_H , der Fahrzeuglängsgeschwindigkeit v_x sowie der Störgrößen ϵ_{QD} beschrieben werden. Auf die Nutzung der Gierrate $\dot{\psi}$ für das Identifikationsvorhaben wird aus technischen Gründen (siehe Abschnitt 3.3.2) verzichtet.

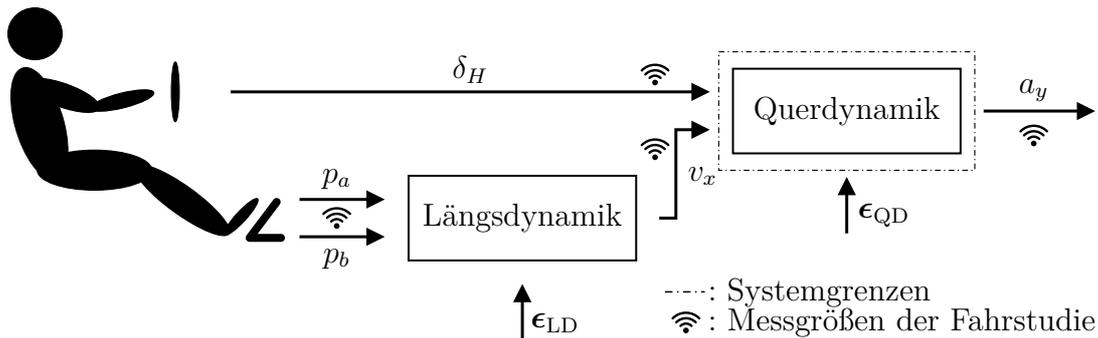


Abbildung 5.1: Definition der Systemgrenzen basierend auf dem Signalfluss im Pkw für überwiegend entkoppelte Systemdynamiken. Rückkopplungen zum Fahrer werden in dieser Abbildung nicht dargestellt.

5.2 Datenbalancierung durch Segmentierung der Fahrten

Eine NDS ermöglicht keine gezielte Aufzeichnung von Fahrdaten (siehe Abschnitt 2.3). Insbesondere für Modelle ohne physikalische Modellbildung besteht das Risiko, dass in

³⁷Eine ausführliche Modellbildung zur Längsdynamik des Versuchsträgers kann VOSS (2021) entnommen werden. Die Arbeit von VOSS (2021) ist als Vorstudie zu dieser Arbeit entstanden und basiert auf Fahrdaten der vorgestellten Studie.

einer Studie ohne Versuchskontrolle die aufgezeichnete Datenbasis für das Identifikationsvorhaben nicht ideal geeignet ist und so Zusammenhänge durch das Modell abgebildet werden, die nicht erwünscht sind (CHOLLET, 2018, S. 5). Durch die gewählte Identifikationsmethode (siehe Abschnitt 2.1.2) werden seltene Ereignisse in den Daten weniger stark gewichtet als häufig auftretende Ereignisse. Es ist daher zu vermuten, dass die Modellgenauigkeit für Bereiche hoher Verteilungsdichten tendenziell höher sein wird als in Bereichen, in denen weniger Daten vorliegen (KUMAR et al., 2012, S. 84). Ein solcher Datensatz wird als nicht balanciert bezeichnet.

Besonders für experimentelle Modelle kann eine ungleichmäßig verteilte bzw. nicht balancierte Datengrundlage zu einer geminderten Modellqualität führen (JOHNSON, KHOSHGOFTAAR, 2019). Die Auswertung der Fahrdaten in Kapitel 4 zeigt insbesondere für den Lenkradwinkel δ_H und für die Querbeschleunigung a_y , dass die beiden Signale nicht gleichverteilt sind und eine Aufbereitung der Daten im Vorfeld zur Identifikation sinnvoll sein kann. Eine Segmentierung der Daten wird vorgenommen.

Die Segmentierung der Daten ist in dieser Arbeit einzig zur Verbesserung des experimentellen Modells vorgesehen. Hierbei soll in die Datenaufbereitung, hier Segmentierung, möglichst wenig spezifisches Modellwissen hinsichtlich der Identifikationsaufgabe einfließen. Auf eine Datenfilterung hinsichtlich bestimmter Fahrereignisse, die bspw. den Fahrmanövern aus Tabelle 2.2 ähneln, wird aufgrund des NDS-Studiendesigns verzichtet (siehe Abschnitt 3.1.2). Das experimentelle Modell soll soweit möglich ohne A-priori-Wissen über die Identifikationsaufgabe erstellt werden.

5.2.1 Segmentierung einer Fahrt in Fahrereignisse

Die Erstellung eines balancierten Datensatzes erfordert eine sinnvolle Datenauswahl. Hierbei werden die Fahrten in Segmente unterteilt, sodass deren zusammenhängender und zeitlicher Charakter nicht verloren geht. Die Datenpakete sollen weiterhin physikalisch interpretierbar und der Eingriff möglichst wenig disruptiv sein. Das Vorgehen orientiert sich an der existierenden Methode der Micro-Trips oder Short-Trips. Diese Methode wird u. a. auf naturalistische Fahrten für die Erzeugung synthetischer Fahrprofile angewandt. Ein Micro-Trip ist definiert als die Dauer zwischen zwei Phasen des Leerlaufs. (GIAKOURIS, 2017)

Micro-Trips finden Anwendung bei Verbrauchsanalysen und fokussieren sich auf die Untersuchung der Längsdynamik des Fahrzeugs. Für die Untersuchung der Querdynamik sind Micro-Trips ungeeignet, da sich deren Kriterium einzig auf die Längsgeschwindigkeit stützt und keine Unterteilung gemäß des Lenkwinkels oder der Querbeschleunigung vornimmt. Für diese Arbeit wird daher eine eigenständige Segmentierung definiert. Eine Fahrt wird unterteilt in Bereiche der Geradeausfahrt (Abk.: GF), in Kurvenereignisse (Abk.: KE) und in Stillstand. Die Segmentierung erfolgt über einen Schwellenwert des Lenkradwinkels und unterteilt eine Fahrt folglich in Bereiche der Längs- und Querdynamik.

- Ein Kurvenereignis wird definiert als das Intervall zwischen einer Neutralstellung des Lenkrades ($\delta_H = 0^\circ$) bis zum erneuten Erreichen dieser Stellung, wenn der Lenkradwinkel δ_H im Maximum einen vorher definierten Schwellenwert überschritten hat. Zwei oder mehrere unmittelbar aufeinanderfolgende Kurvenereignisse werden zu einem einzelnen Ereignis zusammengefasst. Abbremsen in den Stillstand ($v_x = 0 \text{ km/h}$) beendet ein Kurvenereignis vorzeitig.
- Als Geradeausfahrt werden alle Fahrabschnitte bezeichnet, die kein Kurvenereignis sind und in denen die Fahrzeuggeschwindigkeit größer 0 km/h ist.
- Alle verbleibenden Fahrereignisse werden der Gruppe des Stillstands zugeordnet.

Als Schwellenwert für den Lenkradwinkel einer Kurvenfahrt wird $|\delta_H| \geq 10^\circ$ definiert. Dieser Wert wurde experimentell ermittelt und stellt beim Versuchsträger den Übergang von Pendelbewegungen in der eigenen Spur und einem Spurwechsel dar. Grundsätzlich ist die Wahl stark von der Lenkübersetzung des Versuchsträgers und subjektiven Kriterien abhängig.

5.2.2 Segmentierte Studiendaten

Die Anwendung der Segmentierungsregeln auf reale Fahrdaten ist in Abbildung 5.2 für einen Fahrausschnitt über 60s für die drei Messgrößen δ_H , v_x , a_y dargestellt. In dem Verlauf des Lenkradwinkels sind die Neutralstellungen des Lenkrades mit Kreuzen und die Maxima zwischen zwei Neutralstellungen für Werte unterhalb des Schwellenwertes mit Punkten, bzw. für Werte oberhalb des Schwellenwertes mit Dreiecken, markiert. Die Definition der Kurvenereignisse besagt, dass einzelne Kurvenereignisse zu einem zusammenhängenden Ereignis kombiniert werden, wenn sie unmittelbar aufeinanderfolgen. Dies ist der Fall, wenn der erste Datenpunkt aus dem hinteren Kurvenereignis direkt auf den letzten Datenpunkt des vorherigen Kurvenereignisses folgt, ohne dass weitere Datenpunkte aus anderen Fahrereignissen dazwischen liegen. In dem dargestellten Abschnitt liegen zwei solche KE im Zeitraum $t_1 = [243 \text{ s}, 261 \text{ s}]$ sowie von $t_2 = [263 \text{ s}, 285 \text{ s}]$ vor. Kurvenereignisse sind mit einer durchgezogenen Linie dargestellt. Die restlichen Abschnitte werden als Geradeausfahrten klassifiziert (gestrichelte Linie). Die Fahrgeschwindigkeit ist dauerhaft über 0 km/h . Die Segmentierung des gesamten Studiendatensatzes ergibt für die einzelnen Kategorien einen Anteil von 22 % Kurvenereignissen (absolute Anzahl der Ereignisse 7.594), 66 % Geradeausfahrt (absolute Anzahl der Ereignisse 6.894) und 12 % Stillstand³⁸. Die prozentualen Anteile sind bezogen auf die Anzahl der Datenpunkte innerhalb der drei Kategorien.

In Abbildung 5.3 ist die Häufigkeitsverteilung der Messgrößen des Lenkradwinkels δ_H , der Fahrzeuggeschwindigkeit v_x und der Querbewegung a_y für alle Fahrten sowie für die drei Kategorien der Fahrereignisse dargestellt. In der ersten Zeile in Abbildung

³⁸Initialisierungsvorgänge beim Fahrzeugstart bis zur erstmaligen Neutralstellung des Lenkrades werden der Gruppe Stillstand zugeordnet. Dies hat zur Folge, dass die Gruppe Stillstand in der Segmentierung minimal größer ist als die Standzeit aus Tabelle 4.1

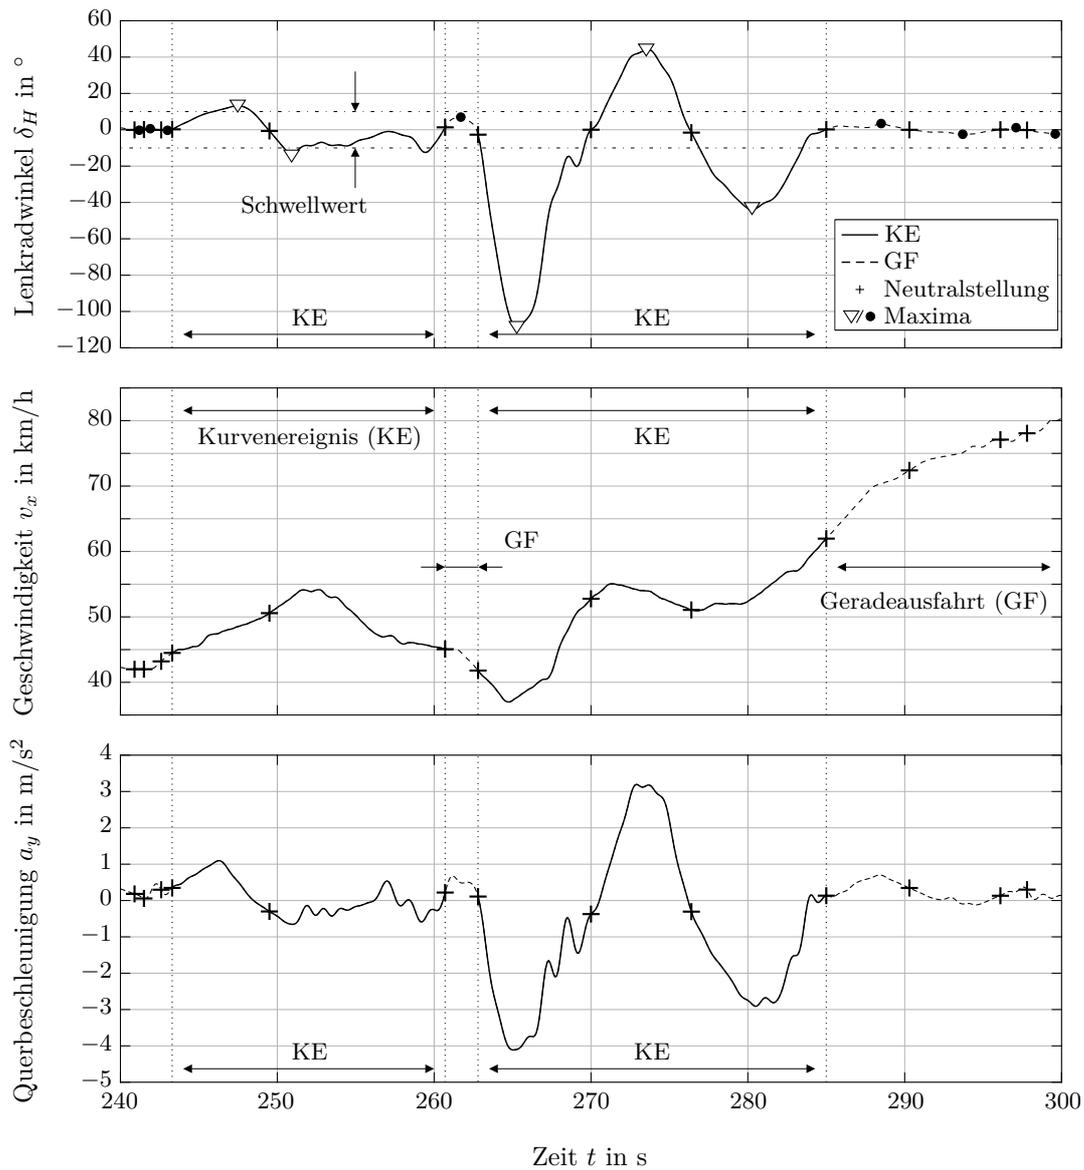


Abbildung 5.2: Segmentierung eines Fahrabschnittes in Kurvenereignisse (KE) und Geradeausfahrt (GF) am Beispiel realer Fahrdaten

5.3 sind die Verteilungen der Messgrößen für alle Fahrten abgebildet. In Zeile 2 bis 4 sind die Verteilungen der Kurvenereignisse, der Geradeausfahrt und des Stillstands dargestellt. Die Summe der Verteilungen der Fahrereignisse ergeben die Verteilung aller Fahrten aus der obersten Zeile. In Tabelle 5.1 sind die Quantile der Messgrößen des Lenkradwinkels δ_H und der Querbeschleunigung a_y für alle Fahrten und für die einzelnen Fahrereignisse aufgelistet. Für die Berechnung der Quantile werden die absoluten Werte der Messgrößen verwendet. Mithilfe der Quantile lässt sich einfach nachvollziehen, inwieweit die Verteilungen der Messgrößen durch die Segmentierung in Fahrereignisse angepasst werden.

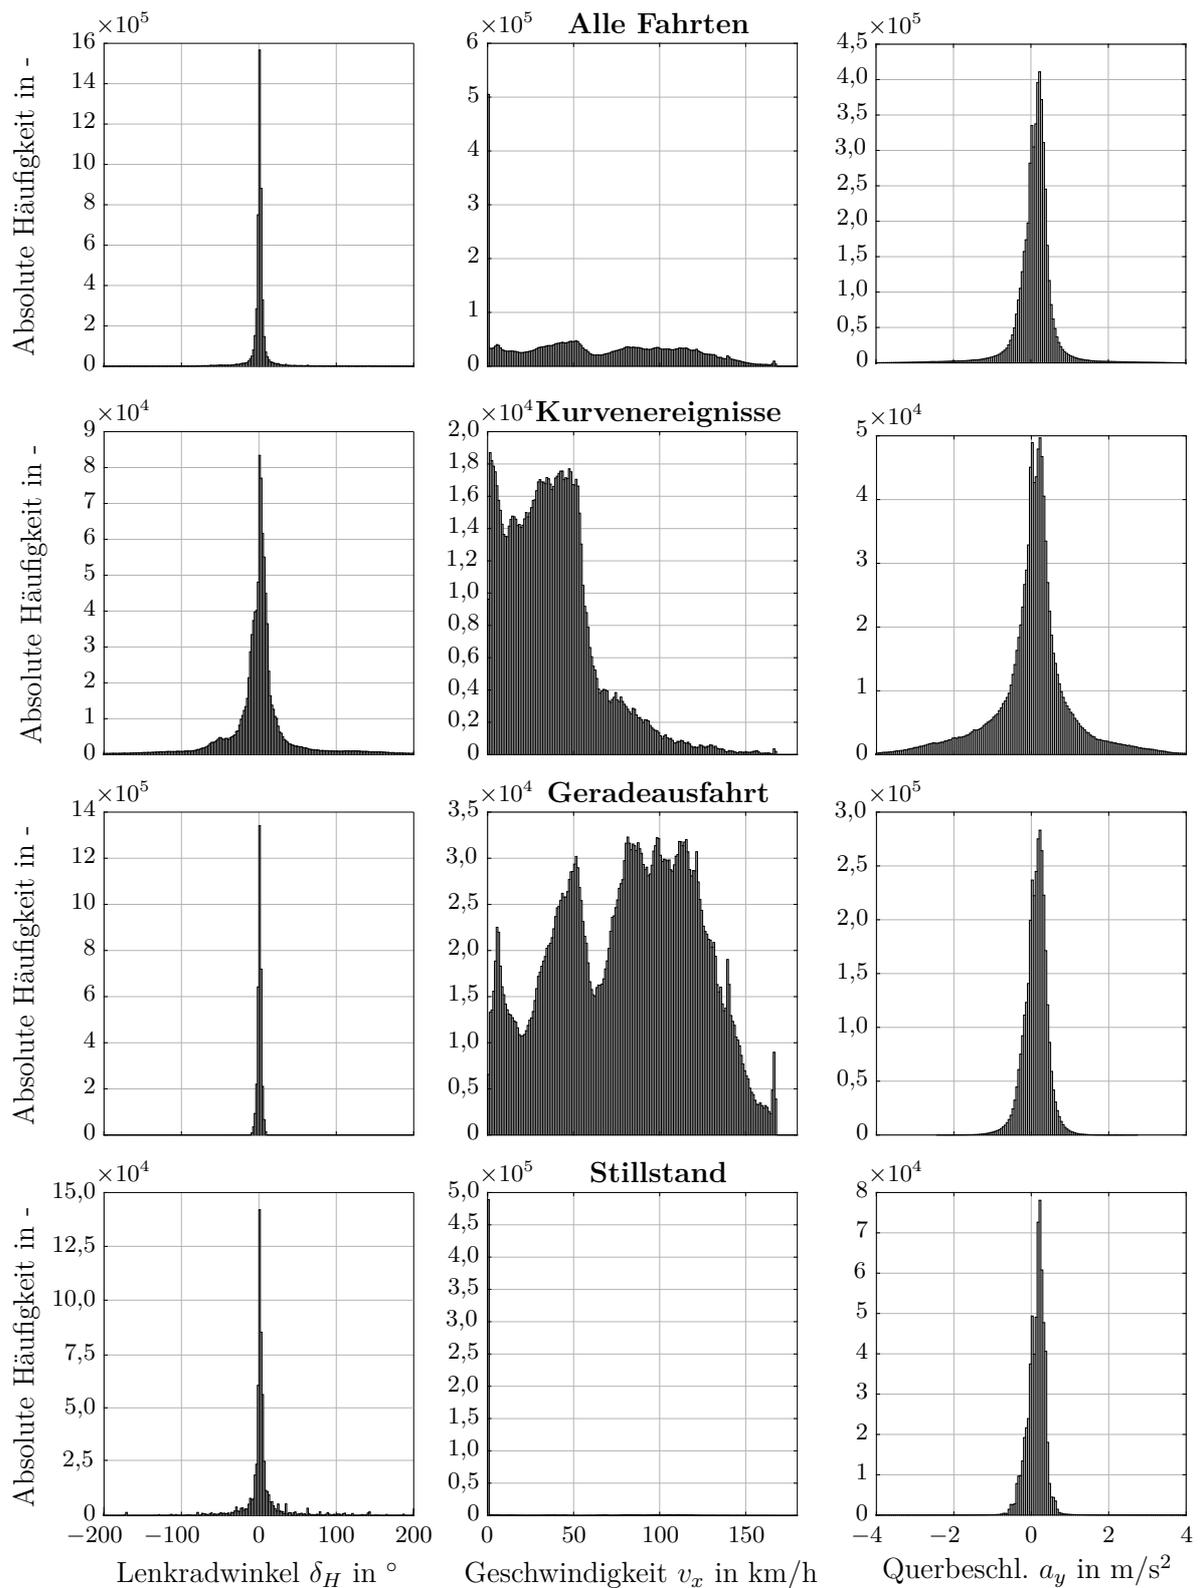


Abbildung 5.3: Häufigkeitsverteilung der Fahrdaten aller Fahrten und segmentiert nach Fahrereignissen

Tabelle 5.1: Quantile der Messgrößen Lenkradwinkel $|\delta_H|$ und Querbearbeschleunigung $|a_y|$ für die verschiedenen Fahrereignisse

	q%-Quantil von $ \delta_H $ in °					q%-Quantil von $ a_y $ in m/s ²				
	50	75	90	99	99,9	50	75	90	99	99,9
Alle Fahrten	2,2	5,1	19,2	266,2	415,9	0,23	0,38	0,65	2,50	3,91
Kurvenereignisse	10,4	30,7	98,3	385,2	419,6	0,37	0,88	1,81	3,49	4,92
Geradeausfahrt	1,6	2,8	4,4	7,6	9,3	0,22	0,34	0,49	0,96	1,44
Stillstand	4,1	15,3	82,1	385,5	418,2	0,20	0,30	0,39	0,68	1,97

Aus Tabelle 5.1 geht hervor, dass für alle Fahrten die Verteilungen von a_y und δ_H sehr hohe Verteilungsdichten für im Betrag kleine Messwerte besitzen. So sind 90 % der Messwerte des Lenkradwinkels kleiner als 20° und für die Querbearbeschleunigung sind 90 % der Messwerte im Betrag kleiner als $0,7 \text{ m/s}^2$. Die 99,9 %-Quantile dieser Messgrößen sind um ein Vielfaches größer als das jeweilige 90 %-Quantil und deuten die Konzentration der Messdaten für im Betrag kleine Werte an. Die hohen Verteilungsdichten für im Betrag kleine Lenkradwinkel δ_H und Querbearbeschleunigungen a_y werden auch in Abbildung 5.3 deutlich. Die Segmentierung wird angewandt, um dieses Ungleichgewicht in der Messgrößenverteilung zu mindern. In der zweiten Zeile sind die Verteilungen der Messgrößen für Kurvenereignisse dargestellt. Die Analyse der Verteilungen der Kurvenereignisse zeigt, dass die Verteilungen des Lenkradwinkels δ_H und der Querbearbeschleunigung a_y gleichmäßiger sind als für alle Fahrten, wenngleich die Verteilungsdichte nahe 0° bzw. 0 m/s^2 weiterhin deutlich höher als für die restlichen Werte ist. Interessanterweise hat sich die Verteilung der Fahrzeuggeschwindigkeit v_x deutlich gegenüber der Verteilung aller Fahrten verändert. Ein Großteil der Geschwindigkeiten für Kurvenfahrten liegt im Geschwindigkeitsbereich bis 60 km/h . Fahrten mit hohen Geschwindigkeiten sind fast ausschließlich der Kategorie Geradeausfahrt zugeordnet (siehe Abbildung 5.3). Für Geradeausfahrten sind die Lenkradwinkel δ_H per Definition auf einen Schwellwert (hier $|\delta_H| \leq 10^\circ$) begrenzt. Als Folge sind die aufgezeichneten Querbearbeschleunigungen gering und liegen im Intervall $[-1,5, 1,5] \text{ m/s}^2$. Für den Stillstand ist die Geschwindigkeit gemäß der Definition $v_x = 0 \text{ km/h}$. Die beobachtete Querbearbeschleunigung im Stillstand ist auf die statische Fahrzeugrotation φ_{stat} (etwa Straßenquerneigung η) und das Sensorrauschen $a_{y,\text{Rauschen}}$ (siehe Abschnitt 3.5) zurückzuführen. In dieser Kategorie sind keine Informationen zur Querdynamik des Fahrzeuges enthalten, sodass die Daten des Stillstands nicht weiter für die Identifikation genutzt werden.

Zusammenfassend kann festgehalten werden, dass es mit der gewählten Segmentierung weiterhin nicht möglich ist, einen vollständig gleichmäßigen Datensatz zu erzeugen. Dies liegt weniger an der Methode als an der Datenverteilung von naturalistischen Fahrten. Bei der Angleichung der Verteilung gehen Datenpunkte verloren. Für die Kurvenereignisse, in denen die meisten Informationen zum querdynamischen Verhalten des Versuchsträgers vermutet werden, gehen 88 % der Daten gegenüber allen Fahrten verloren. Eine weitere Reduzierung der Datenbasis erscheint daher unverhältnismäßig. Ferner wird die Geschwin-

digkeitsverteilung für hohe Geschwindigkeiten beschnitten. Für die Identifikation wird ein sogenannter balancierter Datensatz aus Kurvenereignissen und Geradeausfahrten erstellt. Die Geradeausfahrtanteile werden u. a. benötigt, um den Geschwindigkeitsbereich in den Daten vollständig abzubilden.

Alternative Segmentierungsverfahren sind an dieser Stelle des Identifikationsprozesses denkbar. Für die Segmentierung könnten weitere Kriterien wie etwa die Geschwindigkeit v_x genutzt werden. Für diese Arbeit wird ein Vorgehen gewählt, das den Aufwand der Datenaufbereitung möglichst gering hält und sich auf einen möglichst wenig bearbeiteten Datensatz stützt.

5.3 Theoretische Modellbildung mit einem Linearen Einspurmodell

Für die Beschreibung der Querdynamik eines Pkws eignet sich das Lineare Einspurmodell (Abk.: ESM oder nur Einspurmodell). Das Einspurmodell ist ein Modell mit geringer Komplexität, aber dennoch großer Akzeptanz (MITSCHKE, 2005, S. 1), das bis zu einer Querbeschleunigung von etwa $a_y \leq 4 \text{ m/s}^2$ die querdynamischen Zusammenhänge näherungsweise und physikalisch plausibel abbildet (SCHRAMM, HILLER et al., 2018). Eine Analyse der Studiendaten zeigt, dass die Fahrzustände der Studie im Gültigkeitsbereich des gewählten Modells liegen und die Wahl schlüssig ist.

Die Herleitung der Modellgleichungen und die damit einhergehenden Annahmen und Vereinfachungen werden im Folgenden beschrieben. Hiermit verbunden ist eine Diskussion der Eignung des Modells für die vorhandene Datenbasis.

5.3.1 Mathematische Beschreibung

Für die Modellbildung des Linearen Einspurmodells werden verschiedene Modellannahmen getroffen. Eine Übersicht zu den getroffenen Modellannahmen und Vereinfachungen kann SCHRAMM, HILLER et al. (2018, S. 225) und WILLUMEIT (1998, S. 202-203) entnommen werden und ist im Folgenden aufgelistet:

- Die Modellbildung der Radkinematik entfällt, sodass Hub-, Wank- und Nickbewegungen vernachlässigt werden.
- Der Vortrieb deckt die Fahrwiderstände ab und die Geschwindigkeit des Fahrzeugschwerpunktes ist längs seiner Bahnkurve konstant ($\dot{v} = 0 \text{ m/s}$).
- Die Fahrzeugmasse wird im Massenmittelpunkt CoG zusammengefasst.
- Die Vorder- und Hinterräder werden achsweise zu jeweils einem Rad vereint und die Reifenkräfte greifen jeweils in der Achsmittle an. Folglich werden Reifennachläufe und die Rückstellmomente infolge der Schräglaufwinkel der Reifen vernachlässigt.

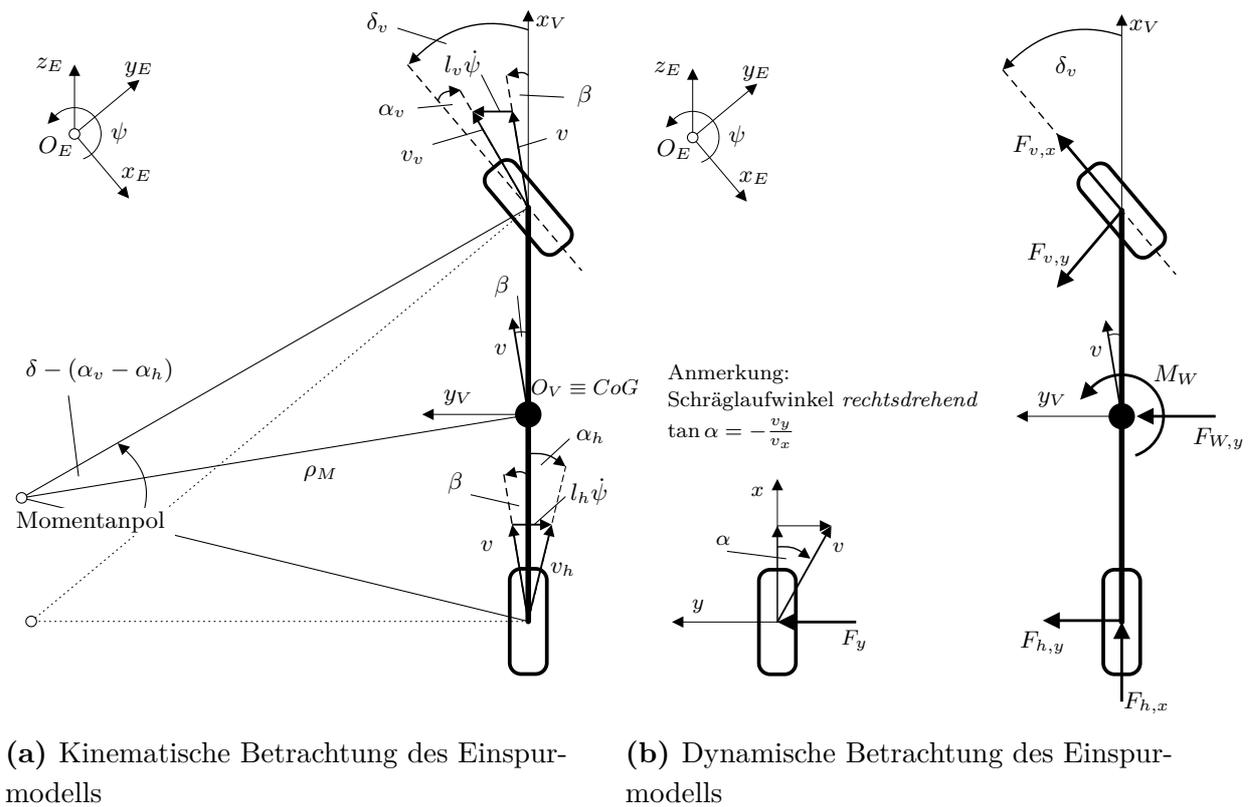


Abbildung 5.4: Mathematische Betrachtung des Einspurmodells

- Die Schräglaufwinkel $\alpha_{v/h}$ werden rechtsdrehend, mathematisch negativ definiert, sodass sie positiv für positive Reifenquerkräfte sind (ISO 8855). Die Schräglaufwinkel $\alpha_{v/h}$ werden als klein angenommen, sodass deren Winkelfunktionen linearisiert werden können. Die Radlastverteilung zwischen Vorder- und Hinterachse bleibt stets konstant, sodass die Reifenquerkraft als Produkt der Schräglaufwinkel und konstanter Schräglauftiefe beschrieben werden kann.
- Der Krümmungsradius der Kurve wird als groß angenommen, sodass sich kleine Gier-, Schwimm- und Lenkwinkel ausbilden und deren Winkelfunktionen linearisiert werden können. Der Schwimmwinkel ist definiert als der Winkel zwischen der Richtung der Schwerpunktschwindigkeit und der Fahrzeuglängsachse.

Aus den ersten beiden Annahmen folgen vier Zwangsbedingungen für die sechs Starrkörperfriheitsgrade des Fahrzeugs (siehe Abschnitt 2.2.1). Das fahrzeugfeste Koordinatensystem \mathbf{K}_V wird in den Fahrzeugschwerpunkt CoG gelegt. Es verbleiben als Bewegungsmöglichkeiten also zwei Freiheitsgrade. Zum einen der Gierwinkel ψ , der ausgedrückt in \mathbf{K}_V nur in der Form der Giergeschwindigkeit $\dot{\psi}$ auftritt, und zum anderen der Schwimmwinkel β . (SCHRAMM, HILLER et al., 2018)

In Abbildung 5.4 wird das Einspurmodell einschließlich der geometrischen Eigenschaften, Geschwindigkeiten und wirkenden Kräfte dargestellt. Aus Gründen der Übersichtlichkeit

ist die Darstellung in kinematische und dynamische Größen unterteilt. Der Schwerpunkt bewegt sich auf einer gekrümmten Bahn um den Momentanpol mit der Geschwindigkeit v . Die Fahrzeuggeschwindigkeit ist orthogonal zum Krümmungsradius ρ_M .

Der Winkel, der sich zwischen Fahrzeuglängsachse x_V und Fahrzeuggeschwindigkeit v einstellt, heißt Schwimmwinkel und wird mit β bezeichnet. Die Geschwindigkeit ${}^V\mathbf{v}$ von CoG im fahrzeugfesten Koordinatensystem $\mathbf{K}_V = \{O_V; x_V, y_V, z_V\}$ kann als

$${}^V\mathbf{v} = \begin{bmatrix} v \cos \beta \\ v \sin \beta \\ 0 \end{bmatrix} \quad (5.2)$$

mit: v = Absolutgeschwindigkeit des Schwerpunkts CoG

β = Schwimmwinkel

beschrieben werden. Durch Differenzierung des Geschwindigkeitsvektors ${}^V\mathbf{v}$ nach der Zeit kann die Beschleunigung

$${}^V\mathbf{a} = \frac{d{}^V\mathbf{v}}{dt} + {}^V\boldsymbol{\omega} \times {}^V\mathbf{v} = \begin{bmatrix} \dot{v} \cos \beta - v(\dot{\psi} + \dot{\beta}) \sin \beta \\ \dot{v} \sin \beta + v(\dot{\psi} + \dot{\beta}) \cos \beta \\ 0 \end{bmatrix} \quad (5.3)$$

mit: $\dot{\psi}$ = Gierrate

bestimmt werden.

Die Bewegungsgleichungen in der xy -Ebene sowie der Drallsatz um die z -Achse im Koordinatensystem \mathbf{K}_V werden zu:

$$\begin{bmatrix} m {}^V a_x \\ m {}^V a_y \\ J_z \ddot{\psi} \end{bmatrix} = \begin{bmatrix} F_{h,x} + F_{v,x} \cos \delta_v - F_{v,y} \sin \delta_v \\ F_{h,y} + F_{v,x} \sin \delta_v + F_{v,y} \cos \delta_v + F_{W,y} \\ -F_{h,y} l_h + F_{v,y} \cos \delta_v l_v + F_{v,x} \sin \delta_v l_v + M_W \end{bmatrix} \quad (5.4)$$

mit: $F_{v/h,x/y}$ = Reifenkräfte vorne/hinten, längs/quer (in x/y-Richtung)

$F_{W,y}$ = externe Kräfte in Querrichtung (bspw. Wind)

M_W = externe Momente um z-Achse (bspw. Wind)

J_z = Trägheitsmoment um z

${}^V a_{x/y}$ = Beschleunigung im fahrzeugfesten Koordinatensystem in x/y-Richtung

$l_{v/h}$ = Abstand der Vorder-/Hinterachse zum Schwerpunkt CoG

m = Fahrzeugmasse

δ_v = Lenkwinkel der Vorderachse

$\dot{\psi}$ = Gierrate

Aerodynamische Effekte, die durch Umwelteinflüsse entstehen, werden als Störgröße betrachtet. In guter Näherung gilt

$$F_{W,y} = M_W = 0. \quad (5.5)$$

Unter Anwendung der Modellannahmen können die Bewegungsgleichungen zu

$$\begin{bmatrix} mv(\dot{\psi} + \dot{\beta})\beta + F_{v,x} + c_{\alpha,v}(\delta_v - \beta - l_v \frac{\dot{\psi}}{v})\delta_v \\ -mv(\dot{\psi} + \dot{\beta}) + c_{\alpha,h}(-\beta + l_h \frac{\dot{\psi}}{v}) + F_{v,x}\delta_v + c_{\alpha,v}(\delta_v - \beta - l_v \frac{\dot{\psi}}{v}) \\ -J_z \ddot{\psi} + c_{\alpha,h}(-\beta + l_h \frac{\dot{\psi}}{v})l_h + c_{\alpha,v}(\delta_v - \beta - l_v \frac{\dot{\psi}}{v})l_v + F_{v,x}\delta_v l_v \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad (5.6)$$

mit: $c_{\alpha,v/h}$ = Schräglaufsteifigkeit der Reifen (vorne/hinten)

vereinfacht werden. Für die Beschreibung der Fahrzeugquerdynamik werden die Bewegungsgleichungen in y -Richtung und der Drallsatz in Zustandsraumdarstellung überführt. Als Zustandsvektor wird $[\dot{\psi}, \beta]^T$ gewählt. Aus Gleichung 5.6 folgt

$$\begin{bmatrix} \ddot{\psi} \\ \dot{\beta} \end{bmatrix} = \begin{bmatrix} -\frac{1}{v} \frac{c_{\alpha,v}l_v^2 + c_{\alpha,h}l_h^2}{J_z} & -\frac{c_{\alpha,v}l_v - c_{\alpha,h}l_h}{J_z} \\ 1 - \frac{1}{v^2} \frac{c_{\alpha,v}l_v + c_{\alpha,h}l_h}{m} & -\frac{1}{v} \frac{c_{\alpha,v} + c_{\alpha,h}}{m} \end{bmatrix} \begin{bmatrix} \dot{\psi} \\ \beta \end{bmatrix} + \begin{bmatrix} \frac{(c_{\alpha,v} + F_{v,x})l_v}{J_z} \\ \frac{1}{v} \frac{c_{\alpha,v} + F_{v,x}}{m} \end{bmatrix} \delta_v. \quad (5.7)$$

Die Querdynamik des Fahrzeugs ist weiterhin über die Umfangskraft $F_{v,x}$ der Vorderreifen mit der Längsdynamik gekoppelt. Für eine konstante Geschwindigkeit v_x kann angenommen werden, dass $c_{\alpha,v} \gg F_{v,x}$ und somit $F_{v,x}$ vernachlässigt werden kann (WILLUMEIT, 1998, S. 206). Für die Anwendung der Modellgleichung auf die Messgrößen des Versuchsträgers wird näherungsweise $v = v_x$ angenommen. Der Modelleingang wird entsprechend der Beschreibung aus Abbildung 2.3 mit \mathbf{u} und der Ausgang mit y_E bezeichnet. Als Modelleingang wird der Lenkradwinkel δ_H gewählt. Die Fahrzeuglenkung wird als ideal starr und direkt, mit einem festen Übersetzungsverhältnis von i_S , angenommen. Für den Eingang des Einspurmodells gilt

$$\delta_v = \frac{1}{i_S} \cdot \delta_H. \quad (5.8)$$

Als weiterer Eingang wird die Fahrzeuggeschwindigkeit v_x genutzt, sodass gilt

$$\mathbf{u} = [\delta_H, v_x]. \quad (5.9)$$

Das Einspurmodell ist somit um den jeweiligen Arbeitspunkt der Geschwindigkeit v_x linear. Als Ausgang y_E wird die Querbeschleunigung a_y gewählt. Im weiteren Verlauf der Arbeit wird die Querbeschleunigung des Einspurmodells mit $a_{y,ESM}$ bezeichnet. Für eine konstante Geschwindigkeit v und kleine Schwimmwinkel β vereinfacht sich Gleichung 5.3 zu

$$y_E = a_{y,ESM} = v_x \cdot (\dot{\beta} + \dot{\psi}). \quad (5.10)$$

Aus Gründen der numerischen Stabilität wird die Modellausgabe für Geschwindigkeiten $v_x \leq 1 \text{ m/s}$ mit $a_y = 0 \text{ m/s}^2$ definiert. So kann eine Division durch kleine Werte von v_x (siehe Gleichung 5.7) vermieden werden.

5.3.2 Eignung des Modells für die Studiendaten

In Abschnitt 5.3.1 werden die Gleichungen des Linearen Einspurmodells hergeleitet und die wesentlichen Annahmen der Modellbildung dargestellt. Eine Überprüfung, inwieweit diese für den vorliegenden Datensatz gültig sind, wird im Folgenden durchgeführt.

Bereits in der Modellbildung wird beschrieben, dass das Einspurmodell für Querbeschleunigungen bis $a_y \approx 4 \text{ m/s}^2$ gute Ergebnisse liefert (SCHRAMM, HILLER et al., 2018, S. 226). In Abbildung 4.6 werden die Beschleunigungsdaten der Fahrstudie und die zugehörigen Quantile dargestellt. 99,9 % aller Beschleunigungsdaten liegen im Bereich $|a_y| \leq 4 \text{ m/s}^2$ (siehe Tabelle 5.1), sodass eine grundsätzliche Eignung des Modells zur Darstellung der Querdynamik alltäglicher Fahrten gegeben ist.

Eine zentrale Annahme der Modellbildung ist die Entkopplung der Längsdynamik von der Querdynamik. Hierbei ist besonders die Annahme kleiner Umfangskräfte und einer konstanten Geschwindigkeit ($\dot{v} = 0 \text{ m/s}^2$) zu nennen. Bei alltäglichen Fahrten ändert sich die Fahrgeschwindigkeit jedoch ständig. Wie jedoch in Abbildung 4.6 gezeigt wird, ist die Beschleunigung für den Großteil der Daten nahe Null ($a_x \approx 0 \text{ m/s}^2$), sodass die Annahme konstanter Längsgeschwindigkeit v_x und geringer Umfangskräfte näherungsweise erfüllt ist. Weiter zeigt der Verlauf der Quantillinien in Abbildung 4.6, dass Datenpunkte maximaler Längsbeschleunigungen stets bei niedrigen Querbeschleunigungen und dass Datenpunkte maximaler Querbeschleunigungen stets bei niedrigen Längsbeschleunigungen gemessen wurden. Die in der Modellbildung vorgenommene Entkopplung der Längs- und Querdynamik wird durch die Daten gerechtfertigt.

In der Modellbildung des Einspurmodells werden die Kräfte am Reifen über den linearen Zusammenhang aus Schräglaufsteifigkeit und Schräglaufwinkel berechnet. Zum Reifen selbst liegen keine Informationen oder Messdaten vor, sodass die getroffenen Annahmen nur plausibilisiert werden können. Für die Reifen einer Achse werden konstante Normalkräfte F_z angenommen. In der Realität wird die Normalkraft durch verschiedene Mechanismen beeinflusst. Sowohl durch starke Längsbeschleunigungen, als auch durch Nicken des Aufbaus wird die Gewichtsverteilung zwischen den Achsen verlagert. Aufgrund der bereits beschriebenen Entkopplung der Längs- und Querdynamik ist dieser Effekt im Modell allerdings vernachlässigt. Weitere Verschiebungen der Normalkraft zwischen dem rechten und linken Reifen einer Achse infolge einer Querbeschleunigung oder infolge von Wanken, gelten bis zu einer Querbeschleunigung von $a_y \approx 4 \text{ m/s}^2$ als vernachlässigbar klein (siehe oben).

Umwelteinflüsse werden durch die Fahrzeugsensorik nicht hinreichend erfasst, sodass deren Einfluss nicht über das Modell beschrieben werden kann. Einige Faktoren, die die Messgröße der Querbeschleunigung beeinflussen, allerdings im Modell nicht erfasst werden, sind

- Änderungen des Fahrzeuggewichts und der Schwerpunktlage durch Zuladung,
- Verschiebungen der Radlasten durch das Fahrbahnprofil (Fahrbahnsteigung, Fahrbahnquerneigung),

- unstetiges Übertragungsverhalten der Reifen durch wechselnden Straßenbelag, Witterungsverhältnisse, Reifendruck, Verschleiß,
- externe Kräfte/Momente durch aerodynamische Effekte.

Die hier aufgezählten Einflüsse können nicht oder nur unzureichend quantifiziert werden. Die Auswirkungen auf das Identifikationsergebnis werden in Kapitel 6 diskutiert.

Die Analyse der getroffenen Modellannahmen zeigt, dass diese sehr gut mit dem vorliegenden Studiendatensatz harmonieren. Es kann davon ausgegangen werden, dass das Einspurmodell geeignet ist, die Querbewegung für die gemessenen Daten zu beschreiben. Einige wenige Datenpunkte liegen außerhalb des Gültigkeitsbereichs des Einspurmodells. Diese höheren Querbewegungen haben Ausreißercharakter und sind für die Identifikation von untergeordneter Bedeutung.

5.3.3 Parameteridentifikation

Die Modellgleichungen des Einspurmodells besitzen sieben Parametern ($m, J_z, l_v, l_h, c_{\alpha,v}, c_{\alpha,h}, i_s$). Der Radstand l kann öffentlich zugänglichen Datenblättern von FORD MOTOR COMPANY (2012) (siehe Anhang A.5) entnommen werden. Für den Radstand l gilt, dass

$$l = l_h + l_v \quad (5.11)$$

ist, sodass die Anzahl unbekannter Parameter auf sechs reduziert werden kann. Ferner kann das Leergewicht des Fahrzeuges den Datenblätter von FORD MOTOR COMPANY (2012) (siehe Anhang A.5) entnommen werden. Da jedoch die Fahrzeugzuladung unbekannt ist, wird die Fahrzeugmasse m als unbekannte Größe behandelt und mit in die Optimierung aufgenommen. Die Wahl der Parametergrenzen kann Anhang A.5 entnommen werden.

Als Optimierungsverfahren wird eine Partikelschwarmoptimierung in Kombination mit einem gradienten-basierten Optimierungsverfahren gewählt. Die Partikelschwarmoptimierung wird in EBERHART, KENNEDY (1995) sowie in KENNEDY, EBERHART (1995) eingeführt. Hierbei wird eine Kostenfunktion $V_{\text{ESM}}(\Theta_{\text{ESM}})$ unter Variation der Parameter $\Theta_{\text{ESM}} = [m, J_z, l_v, c_{\alpha,v}, c_{\alpha,h}, i_s]$ minimiert. Als Kostenfunktion $V_{\text{ESM}}(\Theta_{\text{ESM}})$ wird der Ansatz der kleinsten Fehlerquadrate in Form des RMSE aus Gleichung 2.10 verwendet, wobei

$$e_{k,\text{ESM}} = a_{y,k,\text{ref}} - a_{y,k,\text{ESM}}(\Theta_{\text{ESM}}) \quad (5.12)$$

das Residuum im k -ten Zeitschritt ist und die Differenz aus der gemessenen Querbewegung $a_{y,k,\text{ref}}$ und dem Modellwert $a_{y,k,\text{ESM}}$ darstellt. Der Querbewegungswert des Modells $a_{y,\text{ESM},k}(\Theta_{\text{ESM}})$ hängt u. a. von der Parameterwahl Θ_{ESM} ab. Die Kostenfunktion V_{ESM} wird durch Adaption der Modellparameter

$$\hat{\Theta}_{\text{ESM}} = \underset{\Theta_{\text{ESM}}}{\text{argmin}} V_{\text{ESM}}(\Theta_{\text{ESM}}) \quad (5.13)$$

minimiert. Eine sinnvolle Eingrenzung des Suchraums für die Parameterwahl verkleinert den Optimierungsaufwand. Die Grenzen für die Identifikation werden anhand von Datenblättern und Überschlagsrechnungen festgelegt. Die Berechnung und Definition der Grenzwerte kann Anhang A.5 entnommen werden.

Die Identifikation wird für jede Einzelfahrt sowie für jeden Teildatensatz der Datensätze (S5, S20, S70, S140) aus Abschnitt 4.4 durchgeführt. Hierbei werden ausschließlich die vollständigen Fahrten zur Identifikation verwendet. Der identifizierte Parametersatz $p_{ESM,S140}$ (aller Studiendaten, S140) ist:

$$\Theta_{ESM,S140} = \left[1950 \text{ kg} \quad 2450 \text{ kgm}^2 \quad 72 \cdot 10^3 \text{ N/rad} \quad 134 \cdot 10^3 \text{ N/rad} \quad 1,27 \text{ m} \quad 14,2 \right] \quad (5.14)$$

5.3.4 Eigenlenkgradienten der Subdatensätze

Abbildung 5.5 zeigt die Verteilung der Eigenlenkgradienten EG , die aus den verschiedenen Datensätzen (siehe Abschnitt 4.4) abgeleitet werden. Der Eigenlenkgradient EG ist eine Fahrzeugeigenschaft, die zur Diskussion der Querdynamik eines Fahrzeugs herangezogen werden kann. Er gibt Auskunft, wie ähnlich sich der benötigte Lenkradwinkel δ_H und der rein kinematische Ackermann-Lenkwinkel δ_a für stationäre Zustände sind. Der Lenkwinkel am Vorderrad δ_v wird beschrieben durch:

$$\delta_v = \frac{\delta_H}{i_s} = \delta_a + EG a_y = \underbrace{\frac{l}{\rho_M}}_{\delta_a} + \underbrace{\frac{m}{l} \left(\frac{l_h c_{\alpha,h} - l_v c_{\alpha,v}}{c_{\alpha,v} c_{\alpha,h}} \right)}_{EG} \underbrace{\frac{v^2}{\rho_M}}_{a_y} \quad (5.15)$$

mit: EG = Eigenlenkgradient
 δ_a = Ackermann-Lenkwinkel
 ρ_M = Kurvenradius

Der Eigenlenkgradient hängt von vier der sechs identifizierten Parameter $\hat{\Theta}_{ESM}$ ab. Er eignet sich daher gut als übergeordnete Größe zur Beschreibung des Identifikationsverlaufs auf Basis einer physikalisch interpretierbaren Größe. Der Eigenlenkgradient EG wird für die identifizierten Parameter der verschiedenen Datensätze aus Abschnitt 4.4 berechnet. Für die Einzelfahrten werden entsprechend der Anzahl 273 Eigenlenkgradienten berechnet. Für die 5-Std.-Sätze (S5) werden 31, für die 20-Std.-Sätze (S20) werden 7 EG -Werte bestimmt. Die Verteilungen der Eigenlenkgradienten für die verschiedenen Datensätze werden als Boxplots in Abbildung 5.5 dargestellt. Eine Zusammenfassung zu Boxplots kann Abschnitt 2.5.2 entnommen werden. Für die Datensätze der Größe 70 Std. und 140 Std. existieren zwei Parametersätze bzw. existiert ein Parametersatz, sodass eine Berechnung eines Boxplots nicht möglich ist. Die identifizierten EG -Werte werden in diesen Fällen als Einzelwerte mit Kreuzen dargestellt.

Die Varianz der Verteilung ist für kleine Datenmengen (Einzelfahrten) erwartungsgemäß groß und wird für eine anwachsende Datengrundlage immer kleiner. Der Median der dargestellten Verteilungen ist bereits für kleine Datensätze nahe dem finalen Wert und variiert

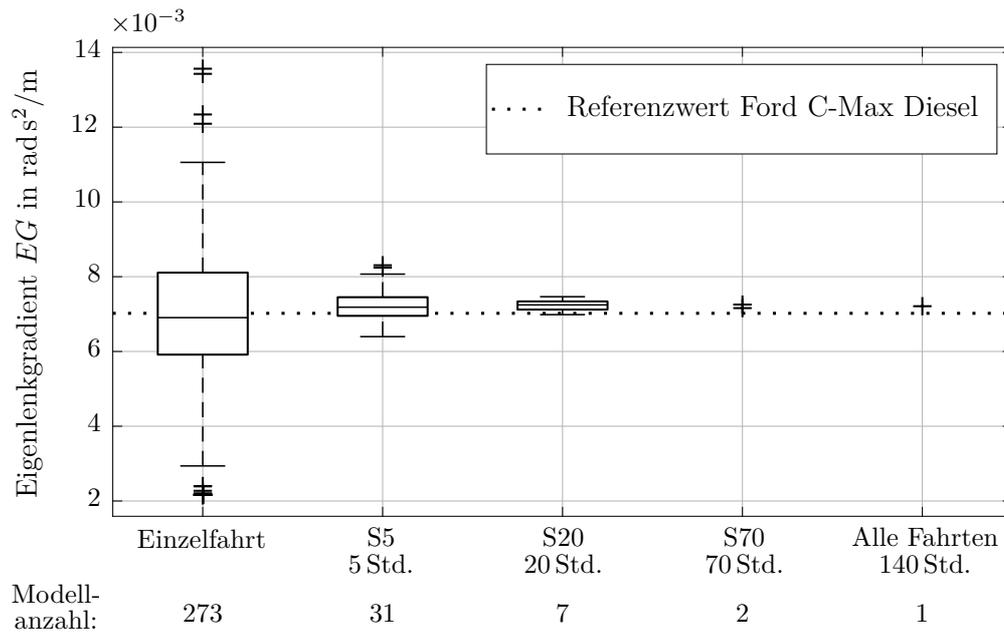


Abbildung 5.5: Identifizierte Eigenlenkgradienten in Abhängigkeit der Datenmenge. Die dargestellte Referenzlinie stammt von einem Ford C-Max Diesel 2.0 l. Abbildung erstmals präsentiert in REICHERTS, HESSE et al. (2021)

für die verschiedenen Datenmengen nur minimal. Der Informationsinhalt für kleine Datensätze ist tendenziell gering. Die Menge der Daten ist nicht ausreichend groß, um eine robuste Identifikation der Parameter zuzulassen, sondern ist anfällig für Ausreißer. Ausreißer werden begünstigt, wenn Datensätze nicht die gewünschten Informationen hinsichtlich der gesuchten Dynamik enthalten oder stark gestört sind. Der Einfluss von Störungen ist für kleine Datensätze entscheidender. Mit steigender Messdauer fallen Ausreißer in den Daten statistisch weniger ins Gewicht.

Bereits für die Datensätze S20 und S70 ist die Varianz sehr klein und die identifizierten Eigenlenkgradienten sind sich sehr ähnlich und weichen nur minimal von dem Wert für alle Fahrten ab. Dies lässt die Schlussfolgerung zu, dass der Informationsgehalt der Datensätze sich ebenfalls angleicht. Die Varianz der identifizierten Parameter oder Modelleigenschaften kann zur Beurteilung der Adäquanz der Daten verwendet werden. Die Beurteilung auf Adäquanz ist unabhängig von der erreichten Modellgenauigkeit und Validität der Modelle zu treffen. (REICHERTS, HESSE et al., 2021)

In Kapitel 4 wird festgehalten, dass die Daten der Fahrstudie für das Identifikationsvorhaben sehr wahrscheinlich adäquat sind. Die in alltäglichen Fahrten zu erwartenden Fahrzustände wurden beobachtet und mithilfe der Kullback-Leibler-Divergenz konnte in Abschnitt 4.3 gezeigt werden, dass sich der Informationszuwachs für die Verteilung der Messgrößen nach etwa 20 Std. stark verlangsamt. Mit der Darstellung der EG für verschieden große Datensätze kann die These zur Adäquanz bestärkt werden. Es ist festzuhalten, dass die Wahrscheinlichkeit einer wesentlichen Veränderung des identifizierten

Eigenlenkgradienten durch weitere Fahrten sehr gering ist und sich folglich auch der Informationsinhalt der Studiendaten nicht wesentlich verändern wird.

Die Validität der Modellparameter wird in Kapitel 6 bewertet. Eine Einschätzung zur Validität der identifizierten Parameter kann anhand der Referenzlinie in Abbildung 5.5 getroffen werden. Der Wert stammt aus einem validierten ADAMS/Chassis-Modell³⁹ eines Ford C-Max Diesel 2.0 l. Die Referenz⁴⁰ in Abbildung 5.5 dient als Orientierungswert und ist nicht als absoluter Zielwert zu verstehen. Abweichungen zwischen der Referenz und den identifizierten Werten können durch Unterschiede der Fahrzeugmodelle (Diesel und Hybrid) entstehen. Das geringere Gewicht der Diesel-Variante führt u. a. zu einem geringeren *EG*. Weitere Abweichungen können durch den verwendeten Reifen sowie Alterung und Verschleiß des Versuchsträgers begründet werden. Es zeigt sich eine gute Annäherung der identifizierten Eigenlenkgradienten zum Referenzwert. Es kann daher davon ausgegangen werden, dass der Identifikationsprozess zu einem gut geeigneten Parametersatz für das theoretische Modell führt.

5.4 Experimentelle Modellbildung mit einem Künstlichen Neuronalen Netz

Als experimentelles Modell wird für die Untersuchungen dieser Arbeit ein Künstliches Neuronales Netz (Abk.: KNN) verwendet. Diese gewinnen für automobiler Anwendungen zunehmend an Bedeutung. Als Anwendungsbereich sind hier virtuelle Sensoren (GRÄBER et al. (2019), BLUME, SIEBERG et al. (2019) und RAHIM et al. (2019)), Fahrdynamikmodelle (HARNACK et al. (2018), VOSS (2021), HOHN (2021), VICENTE et al. (2020) und DA LIO et al. (2020)) oder Regelsysteme (BAHR et al. (2020))⁴¹ zu nennen.

Während für theoretische Modelle die Beziehung zwischen Ein- und Ausgangsgrößen basierend auf physikalischen Zusammenhängen definiert wird, verwenden KNN sogenannte Trainings, um diese Zusammenhänge (automatisiert) zu erlernen. Hierbei erlangt das Modell keinerlei Kenntnis über die Wirkprinzipien, die zu dem Ein-/Ausgangsverhalten führen, können diese aber im Rahmen der trainierten Szenarien sehr gut wiedergeben (CHOLLET, 2018). Insbesondere für Zusammenhänge die entweder physikalisch sehr komplex oder bisher nicht vollständig beschreibbar sind, können KNN eine Alternative oder die einzige Möglichkeit zur Modellbildung darstellen. Genauso bei der Identifikation von Modellen, die aufgrund wenig System- und Modellwissens nicht physikalisch modelliert werden können. Für Anwendungen, in denen es nicht möglich ist, ein schlüssiges theoretisches Modell zu erstellen, können KNN genutzt werden um basierend auf Daten valide Modelle zu erzeugen.

³⁹Bereitgestellt durch die Ford-Werke GmbH

⁴⁰Das Wissen über den Eigenlenkgradienten des Referenzmodells wurde nicht für die Identifikation der Parameter verwendet und erst nach Abschluss der Identifikation zu Vergleichszwecken genutzt.

⁴¹Die Arbeiten von HARNACK et al. (2018), RAHIM et al. (2019), BAHR et al. (2020), HOHN (2021) und VOSS (2021) sind als Vorstudien zu dieser Arbeit entstanden.

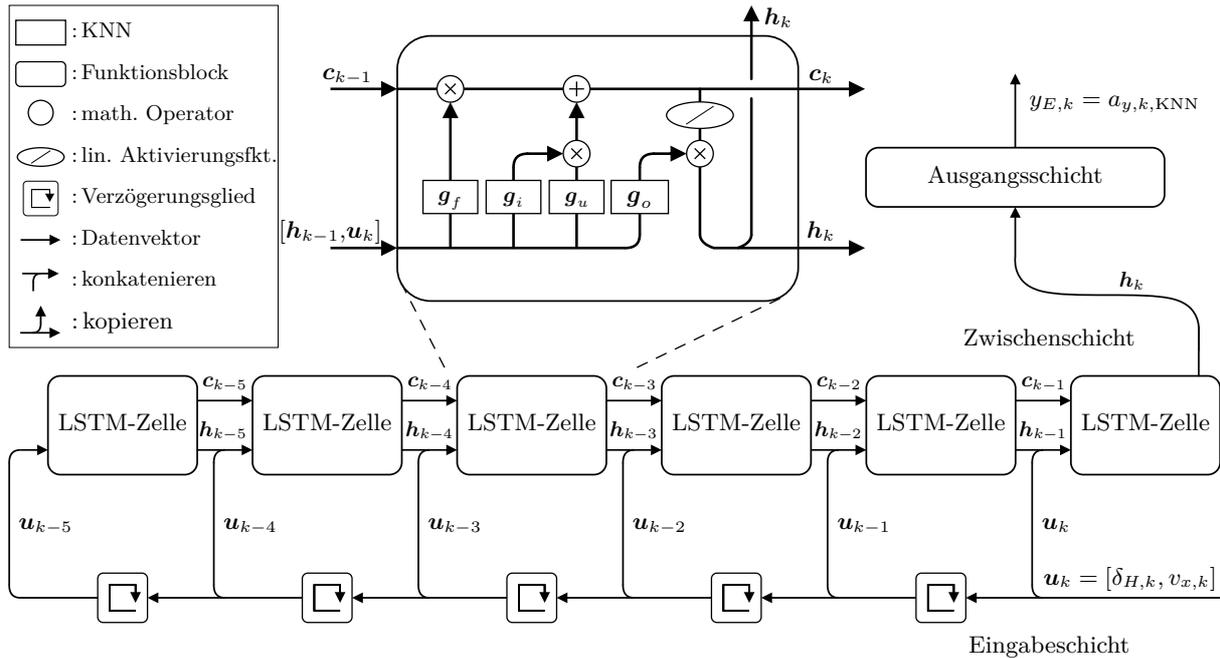


Abbildung 5.6: Netzarchitektur zur Abbildung der Fahrzeugquerdynamik. Die Zwischenschicht besteht aus einer Reihenschaltung von LSTM-Zellen. Die Abbildung ist angelehnt an BLUME, SIEBERG et al. (2019) und OLAH (2015).

KNN bieten für die Identifikation hohe Flexibilität und Modellierungsfreiräume und stellen einen sehr guten Gegenentwurf zum Einspurmodell dar. Die Wahl von KNN als experimentelles Modell ist durch ihre steigende Relevanz und durch die große Spreizung gegenüber dem theoretischen Modell begründet. Es wird untersucht, ob die Identifikation der Querdynamik basierend auf NDS-Daten ohne A-priori-Wissen gelingt. Hierfür müssen sämtliche Informationen zur Querdynamik in den aufgezeichneten Daten enthalten sein.

5.4.1 Auswahl der Netzarchitektur

Das experimentelle Modell zur Berechnung der Querdynamik basiert auf einer rekurrenten Netzarchitektur. Für diese werden LSTM-Zellen (*Long Short-Term Memory*) als Hauptnetzwerkkomponenten verwendet. Diese spezielle rekurrente Schicht ermöglicht das Speichern von Informationen der aktuellen Eingänge über einen bestimmten Zeitraum. Gleichzeitig kann diese Struktur auch eigenständig erlernen, welche Informationen verworfen werden können. Für mechanische Systeme können rekurrente Netzarchitekturen sehr leistungsstark sein. Untersuchungen mit vorwärtsgerichteten Netzen zeigen für diese Arbeit nicht die gleiche Leistung wie LSTM-Zellen, sodass Ansätze mit vorwärtsgerichteten Netzen nicht weiterverfolgt werden.

Der Nutzen von LSTM-Zellen in automobilen Anwendungen wird u. a. von BLUME, SIEBERG et al. (2019), HARNACK et al. (2018) und HOHN (2021) bestätigt. Die Wahl der Modellarchitektur orientiert sich an BLUME, SIEBERG et al. (2019). Nach Durchführung einer Hyperparameter-Optimierung besteht die gewählte Architektur aus einer Eingangsschicht,

einer verborgenen Schicht und einer Ausgangsschicht (siehe Abbildung 5.6). Die Zwischenschicht besteht aus fünf aufeinanderfolgenden LSTM-Zellen. Eine detaillierte Beschreibung der Funktionsweise einer LSTM-Zelle kann GERS, SCHMIDHUBER (2000), GERS, SCHMIDHUBER, CUMMINS (2000) und HOCHREITER, SCHMIDHUBER (1997) entnommen werden. Der Aufbau einer LSTM-Zelle ist in Abbildung 5.6 dargestellt. Die LSTM-Zelle besteht aus vier *Gates* (*Forget, Input, Output, Update Gate*)⁴² sowie jeweils zwei Ein- und Ausgängen. Die Hauptfunktion eines Gates ist es, Signale passieren zu lassen oder zu blockieren. Innerhalb der Gates befinden sich kleine eigenständige Künstliche Neuronale Netze. Das Verhalten der Gates kann über Anpassung der Netzgewichte \mathbf{W} und der Bias \mathbf{b} beeinflusst werden. Der Zellzustand \mathbf{c}_k repräsentiert den Langzeitinformationsspeicher der Zelle und wird durch die Kette an LSTM-Zellen geführt. Die aktuellen Eingänge \mathbf{u}_k sowie ein weiterer Informationsspeicher, die verdeckten Zustände \mathbf{h}_{k-1} , sind die weiteren Signale einer LSTM-Zelle.

Der Modelleingang \mathbf{u}_k besteht aus den Messwerten der Fahrzeuggeschwindigkeit v_x und des Lenkradwinkels δ_H des k -ten Zeitschritts. Diese werden der LSTM-Zelle in standardisierter Form zugeführt. Der Eingangsvektor \mathbf{u}_k wird zusammen mit den versteckten Zuständen \mathbf{h}_{k-1} durch die vier Gates prozessiert.

$$\mathbf{g}_{f,k} = f_{\log} (\mathbf{W}_{hf} \cdot \mathbf{h}_{k-1} + \mathbf{W}_{xf} \cdot \mathbf{u}_k + \mathbf{b}_f) \quad (5.16)$$

$$\mathbf{g}_{i,k} = f_{\log} (\mathbf{W}_{hi} \cdot \mathbf{h}_{k-1} + \mathbf{W}_{xi} \cdot \mathbf{u}_k + \mathbf{b}_i) \quad (5.17)$$

$$\mathbf{g}_{o,k} = f_{\log} (\mathbf{W}_{ho} \cdot \mathbf{h}_{k-1} + \mathbf{W}_{xo} \cdot \mathbf{u}_k + \mathbf{b}_o) \quad (5.18)$$

$$\mathbf{g}_{u,k} = f_{\tanh} (\mathbf{W}_{hu} \cdot \mathbf{h}_{k-1} + \mathbf{W}_{xu} \cdot \mathbf{u}_k + \mathbf{b}_u) \quad (5.19)$$

- mit: \mathbf{u}_k = Modelleingang des k -ten Zeitschritts
 \mathbf{h}_k = versteckte Zustände des k -ten Zeitschritts
 $\mathbf{g}_{f/i/o/u}$ = Ausgabe des KNNs für das *Forget/Input/Output/Update Gate*
 $\mathbf{W}_{x(f/i/o/u)}$ = Netzgewichte der Gates für die Eingängen \mathbf{u}_k
 $\mathbf{W}_{h(f/i/o/u)}$ = Netzgewichte der Gates für die vorherigen Zustände \mathbf{h}_{k-1}
 $\mathbf{b}_{(f/i/o/u)}$ = Bias der Gates
 $f_{\text{id/log/tanh}}$ = Aktivierungsfunktion (Identität, logistisch, Tangens hyperbolicus)

Der Zellzustand \mathbf{c}_k ist eine Kombination aus dem vorherigen Zellzustand \mathbf{c}_{k-1} und den aktuellen Eingaben in $\mathbf{g}_{f,k}$, $\mathbf{g}_{i,k}$ und $\mathbf{g}_{u,k}$:

$$\mathbf{c}_k = \mathbf{g}_{f,k} \circ \mathbf{c}_{k-1} + \mathbf{g}_{i,k} \circ \mathbf{g}_{u,k} \quad (5.20)$$

mit: \mathbf{c}_k = Zellzustand des k -ten Zeitschritts

Der Ausgang der Zwischenschicht

$$\mathbf{h}_k = \mathbf{g}_{o,k} \circ f_{\text{id}} \mathbf{c}_k, \quad (5.21)$$

⁴² Begriffe aus dem Englischen übernommen

welche sowohl vom aktuellen Zellzustand \mathbf{c}_k und den Eingängen (siehe Gleichung 5.18) abhängt, wird in der Ausgangsbeschicht zu einem Ausgang

$$y_{E,k} = \mathbf{W}_{\text{out}} \cdot \mathbf{h}_k = a_{y,k,\text{KNN}} \quad (5.22)$$

verdichtet. Das vollständige KNN besteht aus 66.688 identifizierbaren Parametern (Zusammensetzung aus Netzgewichten \mathbf{W} und Bias \mathbf{b}). Die Anzahl der Parameter ist um ein Vielfaches größer als beim Einspurmodell und bietet dem KNN somit deutlich mehr Freiheitsgrade.

5.4.2 Datenauswahl für das Modelltraining

Für die Identifikation werden erneut die Datensätze (S5, S20, S70 und S140) aus Abschnitt 4.4 verwendet. Für jeden Datensatz werden zwei eigenständige Parametersätze identifiziert. Die erste Modellgruppe basiert auf den vollständigen Daten des jeweiligen Datensatzes. Diese Modelle basieren auf den identischen Daten wie die Einspurmodelle und werden auch im Folgenden mit KNN bezeichnet. Die zweite Modellgruppe des jeweiligen Datensatzes basiert auf dem Ansatz eines balancierten Datensatzes. Hierfür wird jede Fahrt des jeweiligen Datensatzes in die verschiedenen Fahrereignisse (Kurvenereignis, Geradeausfahrt, Stillstand) segmentiert (siehe Abschnitt 5.2). Sämtliche Kurvenereignisse werden dem balancierten Datensatz zugeteilt und durch Geradeausfahrten ergänzt. Die Menge teilt sich zu 75 % in Datenpunkte aus Kurvenfahrten und zu 25 % in Datenpunkte aus Geradeausfahrten auf. Das gewählte Teilungsverhältnis wurde in einer Voruntersuchung experimentell ermittelt und zeigt für eine Teilung von 75 % zu 25 % gute Ergebnisse. Die restlichen Datenpunkte aus Geradeausfahrt und Stillstand werden verworfen. Diese Modelle werden als balancierte Künstliche Neuronale Netze (Abk.: bKNN) bezeichnet. Sowohl die KNN als auch die bKNN basieren auf derselben Netzarchitektur aus Abschnitt 5.4.1. Die Unterschiede liegen somit einzig in der verwendeten Datenbasis.

Von der jeweiligen Datenbasis (vollständig oder balanciert) werden wiederum 75 % für das Training und 25 % zur Validierung des Trainings verwendet. Die Validierung der Modelle an einem unabhängigen (Test-)Datensatz wird in Kapitel 6 diskutiert.

5.4.3 Identifikation bzw. Modelltraining

Die identifizierbaren Parameter Θ_{KNN} der Netzarchitektur aus Abbildung 5.6 sind die Netzgewichte \mathbf{W} und die Bias \mathbf{b} . Das Ziel der Identifikation ist, das Residuum

$$e_{k,\text{KNN}} = a_{y,k,\text{ref}} - a_{y,k,\text{KNN}}(\Theta_{\text{KNN}}) \quad (5.23)$$

aus Messgröße $a_{y,k,\text{ref}}$ und Modell $a_{y,k,\text{KNN}}(\Theta_{\text{KNN}})$ für jeden Zeitschritt k möglichst gering zu halten. Bei der Identifikation bzw. dem Modelltraining ist zu beachten, dass bei einer großen Parameteranzahl und dadurch bedingt einer Vielzahl von Modellfreiheitsgraden die Gefahr einer Überanpassung des Systems an den Trainingsdatensatz gegeben ist. Um

eine Überanpassung zu verhindern, wird eine Regularisierung verwendet. Bei der gewählten Regularisierung wird ein Strafterm zur Fehlerfunktion hinzugefügt. Die Komplexität des KNNs wird beschränkt, indem große Netzgewichte stärker bestraft werden als kleinere. (CHOLLET, 2018, S. 107)

Es wird eine L1-/L2-Regularisierung gewählt. Die Kostenfunktion mit zusätzlicher Regularisierung ist

$$\tilde{V} = \left(\frac{1}{N} \sum_{k=1}^N e_{k,\text{KNN}}^2 + \lambda_{L,1} \sum_{j=1}^p |W_j| + \lambda_{L,2} \sum_{j=1}^p W_j^2 \right)^{\frac{1}{2}}. \quad (5.24)$$

Die Kostenfunktion \tilde{V} wird unter Anpassung der Parameter Θ_{KNN} minimiert, es gilt:

$$\hat{\Theta}_{\text{KNN}} = \underset{\Theta_{\text{KNN}}}{\operatorname{argmin}} \tilde{V}(\Theta_{\text{KNN}}) \quad (5.25)$$

Die initialen Parameter $\Theta_{\text{KNN},0}$ werden zufällig gewählt. Bei der Optimierung der KNN wird ein adaptiver Gradienten-Algorithmus mit Nesterov Momentum verwendet. Weiterführende Informationen können KINGMA, BA (2017) entnommen werden.

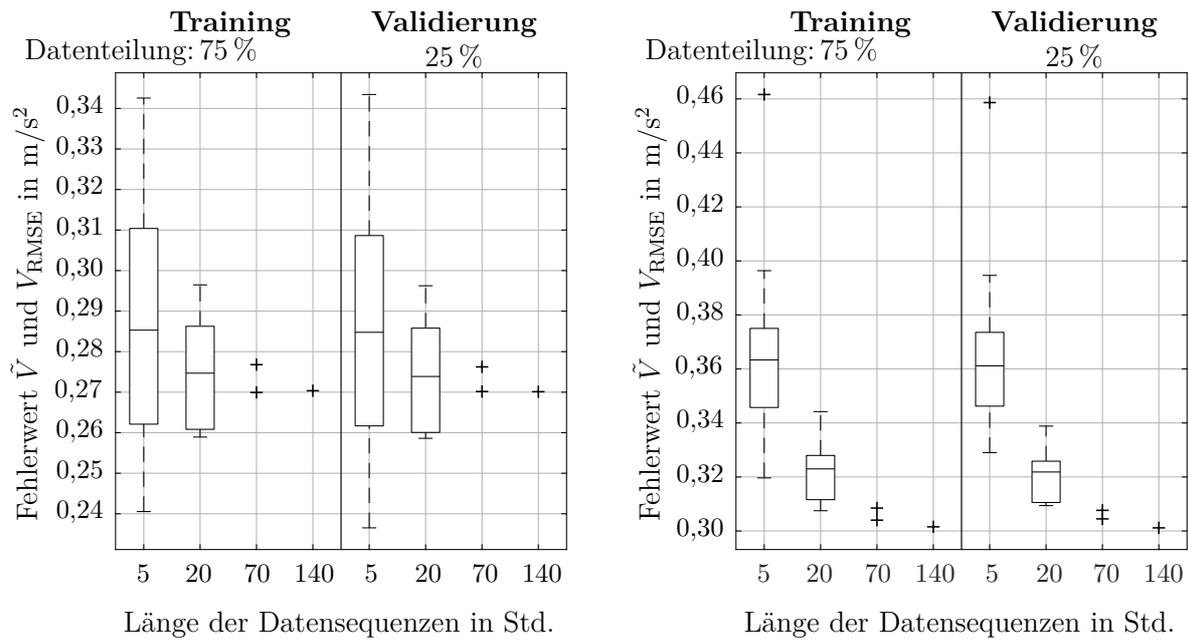
Die Batchsize wird auf 128 Datenpunkte, was einer Fahrdauer von 12,8s entspricht, festgelegt. Für die Trainingsdauer werden 30 Epochen gewählt, da sich der Trainingsverlust nach dieser Dauer nicht mehr signifikant ändert und um gleichzeitig eine Überanpassung der Modelle bei Fortsetzung des Trainings zu verhindern. Um eine Stagnation des Validierungsverlustes während des Trainings zu vermeiden, wird die Lernrate auf Grundlage der Validierungsverluste automatisch reduziert. Die Konfiguration der Optimierungsprozedur wurde in einer Vorstudie experimentell ermittelt. Um den probabilistischen Einfluss der initialen Parameterwahl zu minimieren, werden für jeden Datensatz drei Parametersätze identifiziert. Es wird das Modell mit dem niedrigsten Validierungsfehler für die weiteren Auswertungen gewählt. Die zwei übrigen Modelle werden nicht weiter untersucht.

5.4.4 Auswertung des Modelltrainings

Die Ergebnisse der Identifikation (Modelltraining und Validierung) der KNN und der bKNN werden für die verschiedenen Datensätze in Abbildung 5.7 dargestellt. Die Verteilung der Fehlerwerte \tilde{V} und der RMSE für die Modelle der Datensätze aus Abschnitt 4.4 werden in Boxplots dargestellt (für weitere Erklärungen der Darstellungsform siehe Abschnitt 2.5.2). Für das Modelltraining wird der Fehlerwert \tilde{V} aus Gleichung 5.24 und für die Validierung wird der RMSE aus Gleichung 2.10 (ohne Regularisierungsterm) dargestellt. Auf eine Parameteridentifikation für Einzelfahrten (wie es beim Einspurmodell durchgeführt wird, siehe Abbildung 5.5) wird für die experimentellen Modelle verzichtet. Die Datengrundlage von Einzelfahrten ist in der Regel nicht ausreichend groß.

Die Auswertung der Boxplots dient der Überprüfung auf

- Überanpassung der Modelle auf die Studiendaten und
- Adäquanz der Studiendaten.



(a) Identifikation der KNN mit vollständigen Datensätzen (b) Identifikation der bKNN mit balancierten Datensätzen

Abbildung 5.7: Verteilung der Fehlerwerte für die Trainings- und Validierungsdaten der Künstlichen Neuronalen Netze basierend auf unterschiedlichen Datensätzen

In Abbildung 5.7a sind die Trainings- und Validierungsergebnisse für die KNN basierend auf den Datensätzen aller Studiendaten dargestellt. Die entsprechenden Auswertungen der bKNN sind in Abbildung 5.7b dargestellt. Die Größe der Datensätze nimmt für die Boxplots von links nach rechts zu, die Anzahl der Modelle sinkt gleichzeitig in dieselbe Richtung. So zeigt der Boxplot der 5-Std.-Datensätze (S5) die Verteilung der Fehlerwerte von 31 Modellen. Für die Datensätze aus 20 Std. werden 7 unabhängige Modelle erzeugt. Die Fehlerwerte der 70-Std.- bzw. 140-Std.-Datensätze werden als Einzelwerte (Kreuze) dargestellt.

Sowohl für die KNN in Abbildung 5.7a und die bKNN in Abbildung 5.7b sind die Fehlerwerte im Training und für die Validierung sehr ähnlich. Die Fehlerwerte der Validierungsdaten liegen mit denen der Trainingsdaten auf gleichem Niveau. Eine Überanpassung der Modelle an die Trainingsdaten ist daher wenig wahrscheinlich.

Die Varianz der S5-Modelle ist sowohl für die KNN als auch für die bKNN am größten. Sie wird mit wachsender Datenmenge kleiner. Die Streuung der Fehlerwerte nimmt mit der Datenmenge ab. Ein qualitativ sehr ähnliches Verhalten kann für die Eigenlenkgradienten des Einspurmodells (der theoretischen Modellbildung) in Abbildung 5.5 beobachtet werden.

Für die KNN in Abbildung 5.7a ist unter den identifizierten Modellen der 5-Std.-Datensätze (31 Modelle) sowohl das Modell mit dem höchsten als auch das mit dem niedrigsten RMSE enthalten. Der resultierende Fehlerwert für kleine Datensätze hängt

offensichtlich stark vom Zufall ab. Dies spiegelt sich in der großen Varianz wider. Der Einfluss des Zufalls wird mit steigender Datenmenge limitiert. Die Verteilungen der Datensätze S20 und S70 weisen eine deutlich geringere Streuung und somit höhere Robustheit bei der Identifikation auf. Der Median des Fehlers wird mit steigender Datenmenge kleiner. Hierbei ist allerdings zu beobachten, dass die Verbesserung nicht linear mit der Datenmenge ansteigt, sondern schrittweise kleiner wird. Dies ist wenig erstaunlich, da der Fehlerwert eines Modells nicht beliebig verbessert werden kann. Für eine adäquate Datenmenge ist der Informationszugewinn minimal. Dieses Verhalten kann an den Fehlern der KNN beobachtet werden. Es ist zu vermuten, dass weitere Daten (über 140 Std. hinaus) zu keiner wesentlichen Verbesserung der Modelle führen, sodass auch aus dem Verlauf der Fehlerwerte die Adäquanz der Studiendaten geschlussfolgert werden kann.

In Abschnitt 3.5.3 wird der minimal erreichbare Modellfehler aufgrund des zufälligen Messfehlers (u. a. durch Straßenquerneigung η) abgeschätzt. Die Abschätzung des RMSE, der durch diesen Fehler entsteht, wird mit $0,25 \text{ m/s}^2$ beziffert. Es ist nicht zu erwarten, dass die Modelle diesen Wert unterschreiten. Die Modelle der vollständigen Datensätze aus Abbildung 5.7a liegen mit Ausnahme eines einzelnen Modells eines S5-Datensatzes oberhalb von $0,25 \text{ m/s}^2$. Das Modell, das auf allen Daten (140 Std.) basiert, nähert sich diesem Fehlerniveau bis auf $0,02 \text{ m/s}^2$ an. Dies wird in Anbetracht dessen, dass weitere Störungen in die Identifikation einfließen und Abweichungen zwischen Modell und Messung unvermeidlich sind, als ausreichend gut bewertet. Es ist wenig Steigerungspotential durch weitere Messungen zu erwarten.

Für die bKNN, die Modelle der balancierten Datensätze, kann beobachtet werden, dass für kleine Datensätze die Streuung der Fehlerwerte groß ist und mit steigender Datenmenge abnimmt. Die Fehlerwerte der bKNN sind in Summe größer als die der KNN. Hierbei muss beachtet werden, dass in den balancierten Daten keine Stillstände und weniger Geradeausfahrten enthalten sind und so ein quantitativer Vergleich der Modelle nicht möglich ist. Die Validierung und ein Vergleich der Modelle der verschiedenen Modellierungsansätze erfolgt in Kapitel 6.

Für die bKNN ist erneut die Streuung unter den Modellen aus 5 Std. Fahrdaten am größten. Der Boxplot der S5-Modelle besitzt einen Ausreißer, die Ursache dafür liegt sehr wahrscheinlich in der Balancierung der Daten. Die Datenmenge wird bei der Balancierung beschnitten, Datenpunkte werden entfernt und sehr wahrscheinlich gehen hierbei auch Informationen verloren, was bei kleinen Datensätzen zu inakkuraten Identifikationsergebnissen führen kann. Anders als bei den KNN ist bei den bKNN unter den identifizierten Modellen der 5-Std.-Datensätze zwar das Modell mit dem höchsten RMSE-Wert enthalten, allerdings nicht das mit dem niedrigsten. Der niedrigste RMSE kann bei dem Modell basierend auf dem 140-Std.-Datensatz beobachtet werden. Für die bKNN wird neben der Varianz auch der minimale Fehlerwert für größere Datensätze kleiner. Der RMSE des besten bKNN-Modells nähert sich bis auf $0,05 \text{ m/s}^2$ dem zufälligen Fehlerniveau an. Es ist daher davon auszugehen, dass das Modellverhalten gut abgebildet wird. Eine eingehende Untersuchung erfolgt in Kapitel 6.

KAPITEL 6

Validierung

Die Validität und die Potentiale der identifizierten Modelle aus Kapitel 5 werden für verschiedene Fahrscenarien untersucht. Hierbei kommen sowohl naturalistische Fahrten als auch Fahrmanöver zum Einsatz. Es wird gezeigt, welche Unterschiede sich zwischen den Modellierungsansätzen ergeben. Die in der Arbeit entwickelten Konzepte der Adäquanz und der Datenbalancierung werden ausgewertet und deren Mehrwert wird dargestellt. Der Einfluss der Störung wird beschrieben und es kann gezeigt werden, dass die Modellgenauigkeit ohne Reduzierung der Störung nicht weiter verbessert werden kann. Für fahrdynamische Zustände, die im Identifikationsdatensatz nur selten beobachtet wurden, zeigen die identifizierten Modelle hohe Güte und Robustheit.

6.1 Validierungsanforderung

Im Verlauf des Kapitels wird die Validität der theoretischen und experimentellen Modelle untersucht. Als Modellvalidierung wird die Prüfung eines Modells hinsichtlich eines definierten Anwendungsbereichs verstanden. Für Fahrdynamiksimulationen beschreiben HEYDINGER, GARROTT et al. (1990), dass – unter Einhaltung einer bestimmten Genauigkeit – mithilfe der Modellvalidierung für einen definierten Betriebsbereich des Fahrzeugs die Übereinstimmung der Vorhersagen einer Simulation mit den tatsächlich gemessenen Reaktionen des Fahrzeugs nachgewiesen wird.

Die Genauigkeit eines Simulationsmodells ist grundsätzlich limitiert. Neben Fehlern im Modell selbst entsteht ein Teil der Abweichung zur Referenz durch zufällige Messfehler (Messrauschen oder in diesem Fall äußere Störgrößen, siehe Abschnitt 3.5). Diese zufäl-

ligen Fehler führen zwangsläufig zu einem Residuum zwischen den Mess- und Modellwerten. HEYDINGER, GARROTT et al. (1990, S. 3) empfehlen daher, Simulationen bzw. Simulationsmodelle als gültig zu betrachten, wenn die Simulationsergebnisse innerhalb des zufälligen Fehlerniveaus der experimentellen Messungen liegen.

Für die Identifikation aus Kapitel 5 werden Daten aus alltäglichen Fahrten genutzt. Es wird gefordert, dass die identifizierten Modelle für eben diesen Betriebsbereich, der alltäglichen Fahrten valide sind. Eine Aussage zu der erreichten Modellqualität wird durch den starken Einfluss der Störgrößen (Abschnitt 3.5) auf den Messwert erschwert.

In dieser Arbeit werden die identifizierten Fahrdynamikmodelle als hinreichend genaue Abbildung der Realität und somit als valide betrachtet,

1. *wenn der RMSE-Fehlerwert für einen ungesesehenen naturalistischen Validierungsdatensatz (siehe Tabelle 5.1) im Genauigkeitsbereich des zufälligen Fehlerniveaus (siehe Abschnitt 3.5) liegt,*
2. *das Residuum für jeden Simulationsschritt den maximalen Störgrößeneinfluss von $0,75 \text{ m/s}^2$ (siehe Abschnitt 3.5.2) plus eine zusätzliche 10%-ige Abweichung zwischen Modell- und Messwert nicht überschreitet sowie*
3. *das Eigenlenkverhalten des Versuchsträgers im Beschleunigungsbereich bis $|a_y| \leq 4 \text{ m/s}^2$ qualitativ korrekt abgebildet wird.*

Werden diese Validitätskriterien erfüllt, wird dies als Nachweis des Forschungsvorhaben aus Abschnitt 2.8 gewertet, dass NDS für den Identifikationszweck der Fahrdynamik, hier am Beispiel der Vorhersage der Querschleunigung für naturalistische Fahrten, genutzt werden können.

Der Einfluss der Datenmenge auf die Validität der Modelle wird untersucht, zudem werden die Unterschiede zwischen den theoretischen und den experimentellen Modellen dargestellt. Die Validierungsziele der Modellierungsarten und die Schlussfolgerungen, die gezogen werden können, sind für die jeweiligen Modellierungsarten unterschiedlich.

- **Parameteridentifikation des theoretischen Modells**

Die Modellvalidität des Einspurmodells ist ausreichend untersucht und die Grenzen des Modells sind bekannt (siehe Abschnitt 5.3). Im Identifikationsprozess dieser Arbeit wird die valide Modellstruktur genutzt und ein Parametersatz gesucht, der die Fahrdynamik des Versuchsträgers beschreibt. Das Ziel der Modellvalidierung für das Einspurmodell ist folglich der Validitätsnachweis der identifizierten Parametersätze. Gelingt die Identifikation eines validen Parametersatzes, ist dies ein Nachweis, dass die Identifikation als solche gelingt und ausreichend Informationen zum dynamischen Verhalten im Datensatz vorliegen.

- **Generalisierbarkeit des experimentellen Modells**

Künstliche Neuronale Netze sind Black-Box-Modelle. Die Validität dieser Modelle kann nicht durch Abtesten einzelner Betriebsbereiche bestimmt werden. Es wird

daher keine Validität, sondern Generalisierbarkeit⁴³ gefordert. Der Gültigkeitsbereich des experimentellen Modells wird anders als beim theoretischen Modell nicht durch physikalische Grenzen festgelegt, sondern durch die im Training erlernten Zusammenhänge. Eine Analyse der Modellvorhersagen für selten oder nie beobachtete Fahrzustände ist von besonderem Interesse. Die Modellgenauigkeit wird somit über die notwendigen Anforderungen hinaus untersucht.

Zeigen die KNN für ungesehene Eingänge ein valides Systemverhalten, wird dies als Nachweis gewertet, dass die Identifikation ohne A-priori-Wissen gelingen kann und sämtliche Informationen zum gesuchten Systemverhalten in den Studiendaten enthalten sind.

Sowohl für die Modellbildung als auch für die Validierung kommen für gewöhnlich kurze, aber klar definierte Experimente (Manöverfahrten, z. B. Spurwechsel, Lenkwinkelsprung usw., siehe Tabelle 2.2) zum Einsatz, die keine realen Fahrsituationen nachahmen, sondern bestimmte Zustände eines Fahrzeugs anregen. Diese extremen Fahrsituationen sind in realen Fahrten sehr selten zu finden (siehe Abschnitt 4.2). Für die Analyse der Validität der Modelle für alltägliche Fahrten sind solche Manöver nicht notwendig, wenngleich eine Analyse der Modelle in diesem Dynamikbereich interessant ist, um umfängliche Aussagen zur Modellgenauigkeit und zum Dynamikbereich der Modelle treffen zu können. Eine Analyse hochdynamischer Manöver wird daher zusätzlich zu den Analysen, die aufgrund der Validitätsanforderungen notwendig sind, durchgeführt. Insbesondere die Dynamiken transienter Manöver sind in alltäglichen Fahrten selten. Diese zeichnen sich durch schlagartige Lastwechsel mit hohen Lenkwinkelgeschwindigkeiten bei gleichzeitig hoher Längsgeschwindigkeit aus. Zur Untersuchung werden daher neben Daten aus realen Fahrten auch Daten aus Vergleichssimulationen genutzt.

Untersuchungsziele:

- Nachweis, dass NDS für Identifikationszwecke geeignet ist.
 - Nachweis, dass die Identifikation der Querdynamik basierend auf physikalischen Modellparametern gelingt.

Der Nachweis gelingt, wenn für das theoretische Modell ein Parametersatz gefunden werden kann, der das dynamische Verhalten beschreibt und dessen Genauigkeit hinreichend gut ist, um im geforderten Genauigkeitsbereich zu liegen (siehe Anforderungen). Ferner wird gefordert, dass das Eigenlenkverhalten im linearen Bereich valide identifiziert wird. Dies wird als Nachweis verstanden, dass die Identifikation der Querdynamik basierend auf physikalischen Modellparametern gelingt und ausreichend Informationen zum querdynamischen Verhalten im Datensatz vorliegen.

⁴³Generalisierbarkeit ist eine Eigenschaft des KNNs, für unbekannte Eingänge valide Ausgangsgrößen zu bestimmen (BISHOP, 2006, S. 2). Im weiteren Verlauf des Kapitels werden die Analysen zur Modellgenauigkeit für die theoretische und experimentelle Modellbildung zusammengefasst. Auf eine Trennung der Begrifflichkeiten Validität und Generalisierbarkeit wird verzichtet.

- Nachweis, dass die Identifikation der Querdynamik ohne A-priori-Wissen gelingt.

Für die experimentellen Modelle wird gefordert, dass das identifizierte Modell das dynamische Verhalten des Versuchsträgers hinreichend genau (siehe Anforderungen) beschreibt. Dies wird als Nachweis verstanden, dass die Identifikation der Querdynamik auch ohne A-priori-Wissen gelingt und sämtliche Informationen zum querdynamischen Verhalten im Datensatz vorhanden sind.

- Darstellung des Dynamikbereichs der (experimentellen) Modelle.
- Beschreibung des Einflusses der Studiendauer und Adäquanz auf das Identifikationsergebnis.
- Beschreibung des Nutzens der Datenbalancierung für die experimentellen Modelle.
- Beschreibung der Limitierungen des gewählten Studiendesigns für das Identifikationsvorhaben.

6.2 Validierung an naturalistischen Fahrten

Die Validierung wird u. a. an naturalistischen Fahrten durchgeführt. Hierfür wird, entsprechend der Vorgaben des Identifikationsprozesses (siehe Abbildung 3.1), ein neuer Datensatz genutzt. Der neue Datensatz ist unabhängig von den bisherigen Fahrdaten der Studie und wird nicht zur Modellbildung in Kapitel 5 verwendet. Die Validierungsdaten bilden Fahrten über einen Zeitraum von einem Monat ab. Die verwendete Methodik zur Datenaufnahme entspricht der aus der übrigen Fahrstudie (siehe Abschnitt 3.2). Der Zeitraum wird als *Validierungsmonat* und die Daten mit $Z_{V,VM}$ bezeichnet.

6.2.1 Fahrdaten des Validierungsmonats

Die vorliegenden Validierungsdaten decken Fahrten im direkten Anschluss an die Fahrstudie ab und repräsentieren die Nutzung des Fahrzeugs vom 1.7.2020 bis 31.7.2020. Sie umfassen 26 Fahrten, bei einer gesamten Fahrzeit von 8 Std. und einer Fahrstrecke von etwa 500 km. Einige Eigenschaften des Validierungsdatensatzes $Z_{V,VM}$ sind in Tabelle 6.1 aufgelistet. Die Messgrößenverteilung der Fahrzeuggeschwindigkeit v_x , der Geschwindigkeit des Lenkradwinkels $\dot{\delta}_H$ und der Fahrzeugbeschleunigungen $[a_x, a_y]$ werden untersucht. Diese sind in Abbildung 6.1 dargestellt.

- **Fahrzeuggeschwindigkeit v_x**

Die Verteilung der Geschwindigkeit v_x ist in Abbildung 6.1a dargestellt. Der aufgezeichnete Geschwindigkeitsbereich deckt den möglichen Geschwindigkeitsbereich des Versuchsträgers vollständig ab. Die Modenausprägung der Verteilung weicht leicht von der Verteilung der Studiendaten $Z_{V,Studie}$ aus Abbildung 4.3a ab. Auffällig ist die hohe Verteilungsdichte für die maximale Geschwindigkeit. Dies kann durch eine längere Autobahnfahrt im Datensatz erklärt werden.

Tabelle 6.1: Merkmale der Fahrdaten $Z_{V,VM}$ des Validierungsmonats

	Alle Fahrdaten
Zeitraum	Juli 2020
Anzahl der Fahrten	26
Fahrstrecke gesamt in km	491
Fahrdauer gesamt in Std.	8
Mittlere Fahrstrecke in km	19
Mittlere Fahrdauer in min	18
Mittlere Geschwindigkeit in km/h	61
Anzahl der Fahrten/Tag	0,84

- **Geschwindigkeit des Lenkradwinkels $\dot{\delta}_H$**

Die Verteilung der Lenkradwinkelgeschwindigkeit $\dot{\delta}_H$ ist in Abbildung 6.1b dargestellt. Die Dynamik der Lenkbewegung in den Fahrdaten des Validierungsmonats $Z_{V,VM}$ ist niedrig. Hohe Lenkwinkelgeschwindigkeiten sind im Datensatz selten, so dass transiente Manöver (häufig $\dot{\delta}_H \geq 180^\circ/\text{s}$) mit diesen Daten nicht vollständig validiert werden können.

- **Fahrzeugbeschleunigungen $[a_x, a_y]$**

Die Beschleunigungswerte der Validierungsdaten $Z_{V,VM}$ sind in einem Beschleunigungsdiagramm von $[a_x, a_y]$ in Abbildung 6.1c dargestellt. Die Quantillinien des 50 %-, 75 %- und 90 %-Quantils⁴⁴ sind zusätzlich zu den Datenpunkten in dem Beschleunigungsdiagramm eingezeichnet. Ein Vergleich mit den Studiendaten $Z_{V,Studie}$ zeigt einen ähnlichen Verlauf der maximalen Beschleunigungswerte und Quantillinien (vgl. Abbildung 4.5 und 4.6).

Die Validierungsdaten $Z_{V,VM}$ sind den Daten der Fahrstudie $Z_{V,Studie}$ in vielen Eigenschaften ähnlich und eignen sich daher gut zur Untersuchung der Modellvalidität hinsichtlich alltäglicher Fahrten. Ein Nachweis der Zweckmäßigkeit der Identifikation mit NDS-Daten kann so erbracht werden. Zur Validierung transienter und hochdynamischer Zustände ist der Datensatz ungeeignet. Eine Validierung für diesen Bereich basierend auf den Daten $Z_{V,VM}$ ist nicht möglich.

6.2.2 Fehlermetrik

Zur objektiven Bewertung der Modellvalidität wird im Folgenden die mittlere Fehlerquadratsumme (RMSE, aus Gleichung 2.10) verwendet. Das Residuum e_k ist

$$e_k = a_{y,k,\text{sen}} - a_{y,k,\text{sim}} \quad (6.1)$$

⁴⁴Die Quantillinien des 99 %- und 99,9 %-Quantils lassen sich aufgrund der geringen Datenmenge nicht sinnvoll darstellen.

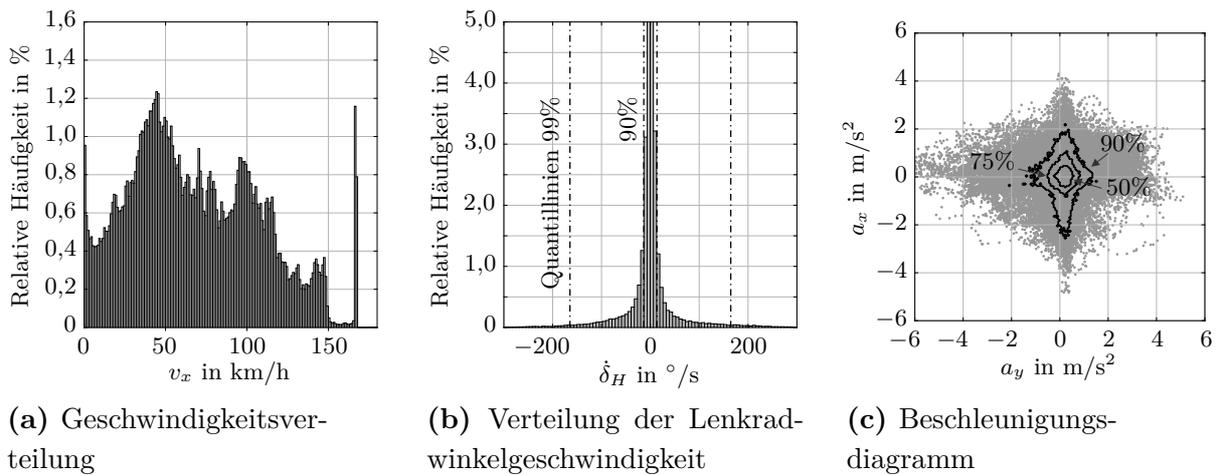


Abbildung 6.1: Verteilung relevanter Messgrößen in den Fahrdaten des Validierungsmonats $Z_{V,VM}$

und besteht aus dem Messwert $a_{y,k,sen}$ und dem Modellwert $a_{y,k,sim}$ der Querbewegung zum k -ten Zeitschritt. Durch diese werden Informationen zur Genauigkeit einer Fahrt (oder der Summe mehrerer Fahrten) auf einen Einzelwert reduziert und ein Vergleich verschiedener Modelle wird ermöglicht. Dabei geht ein gewisser Teil der Informationen verloren, sodass dieses Kriterium nicht ohne weitere Auswertungen genutzt werden sollte. Der RMSE basiert auf der Methode der kleinsten Fehlerquadrate aus Gleichung 2.10, die bereits als Kostenfunktion der Identifikationsmethode verwendet wird.

In Tabelle 6.2 sind die Ergebnisse der Fehlermetrik für das Einspurmodell und das KNN in Bezug auf die Validierungsdaten aufgelistet. Wie bereits in Kapitel 5 beschrieben, werden die Studiendaten in Sätze ähnlicher Größe (S5, S20, S70, S140) zerteilt und basierend auf diesen Datensätzen Modelle identifiziert. Weitere Beschreibungen zu den Datensätzen können Abschnitt 4.4 entnommen werden. Die Verteilung der Fehlermetrik der unterschiedlichen Datensätze für das Einspurmodell⁴⁵ und das KNN sind in Abbildung 6.2 als Boxplots dargestellt (für Erläuterungen der Darstellungsform siehe Abschnitt 2.5.2). Die Fehlerwerte der S70- und S140-Datensätze werden in Abbildung 6.2 als Einzelwerte (Kreuze) dargestellt. In Tabelle 6.2 sind zusätzlich die Zahlenwerte der charakteristischen Verteilungsmerkmale – der maximale/minimale Fehlerwert, der Median und der Mittelwert – aufgeführt.

Einspurmodell

Für das Einspurmodell ist die Streuung der Modelle aus wenigen Daten groß und nimmt mit zunehmender Datenmenge ab. Für die identifizierten Modelle basierend auf den

⁴⁵Auf eine Darstellung der RMSE für Einzelfahrten des Einspurmodells wird verzichtet, da diese die Übersichtlichkeit einschränken und für KNN keine vergleichbaren Modelle existieren. Die Gründe werden in Abschnitt 5.4.4 beschrieben. Die Fehlerwerte der Einzelfahrten können Tabelle 6.2 entnommen werden.

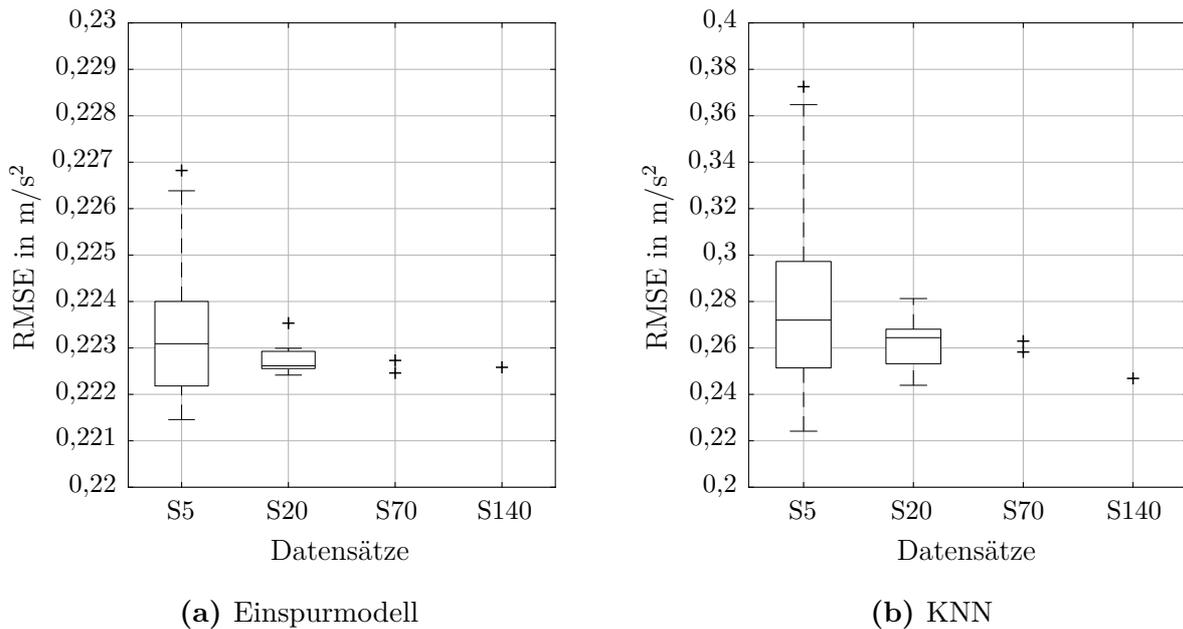


Abbildung 6.2: Boxplots der RMSE-Fehlerwerte der Validierungsdaten $Z_{V,VW}$ für die Modelle (Einspurmodell und KNN) der unterschiedlichen Datensätze

273 Einzelfahrten liegen der maximale und minimale RMSE zwischen $0,2215 \text{ m/s}^2$ und $0,2864 \text{ m/s}^2$ (siehe Tabelle 6.2). Bereits für die Modelle der Datensätze S5 wird diese Spreizung zwischen maximalem und minimalem RMSE deutlich kleiner und die Fehlerwerte haben sich bis auf die zweite Nachkommastelle angenähert. Eine weitere Abnahme der Streuung kann für die Modelle der S20-Datensätze beobachtet werden, bis schließlich die Streuung der Fehlerwerte der S70-Datensätze auf $0,2225 \text{ m/s}^2$ bis $0,2227 \text{ m/s}^2$ begrenzt ist.

Weiter kann beobachtet werden, dass zusätzlich zur Streuung auch der mittlere Fehlerwert sowie der Median mit zunehmender Datenmenge abnehmen. Durch Hinzufügen weiterer Daten kann die Modellgenauigkeit nicht beliebig weiter erhöht werden. Die RMSE für Datensätze über 20 Std. ändern sich nur noch geringfügig (siehe Abbildung 6.2a).

Tabelle 6.2: Fehlermetriken der verschiedenen Einspurmodelle und KNN für die Daten des Validierungsmonats $Z_{V,VM}$

	RMSE _{ESM} in m/s^2				RMSE _{KNN} in m/s^2			
	min	max	Median	Mittel	min	max	Median	Mittel
S140	0,2226				0,2469			
S70	0,2225	0,2227	–	0,2226	0,2583	0,2629	–	0,2606
S20	0,2224	0,2235	0,2226	0,2228	0,2439	0,2813	0,2644	0,2619
S5	0,2215	0,2268	0,2231	0,2233	0,2241	0,3725	0,2720	0,2770
Einzelfahrt	0,2215	0,2864	0,2247	0,2281	–	–	–	–

Die Genauigkeit der resultierenden Einspurmodelle liegt verhältnismäßig nah beieinander ($0,2215 \text{ m/s}^2$ bis $0,2864 \text{ m/s}^2$). Dies kann durch ausreichend A-priori-Wissen erklärt werden, das in Form der physikalischen Modellstruktur und der Parametergrenzen in die Identifikation eingeflossen ist. Unabhängig vom Datensatz kann kein Parametersatz gefunden werden, der einen RMSE unter $0,22 \text{ m/s}^2$ besitzt. Eine Diskussion, weshalb ein Fehlerwert dieser Größenordnung zu erwarten ist, kann Abschnitt 3.5 entnommen werden. Wenn weitere Messungen keine oder nur sehr wenige weitere Informationen zur Verbesserung der Modellgenauigkeit beitragen, kann der Datensatz für die Anwendung als adäquat bewertet werden. Dies wird für das Einspurmodell mit den Datensätzen S70 erreicht.

Künstliches Neuronales Netz

In Abbildung 6.2b wird die Verteilung der RMSE der KNN für verschiedene Datensätze dargestellt. Für Modelle mit kleiner Datensatzgröße ist die Streuung unter den Modellfehlern groß. Die Streuung nimmt mit der Größe der Datensätze ab. Für die Datensätze S5 liegen die Fehlerwerte zwischen $0,2241 \text{ m/s}^2$ und $0,3725 \text{ m/s}^2$. Die Streuung nimmt für die nächstgrößere Gruppe der S20-Datensätze deutlich ab und reicht von $0,2439 \text{ m/s}^2$ bis $0,2813 \text{ m/s}^2$. Die Identifikation der Querdynamik wird folglich mit dem Anstieg der Datenmenge robuster und die Modelle gleichen sich in ihrem Verhalten zunehmend an. Die These nach einer Sättigung des Informationszuwachses und der adäquaten Datenmenge wird durch die Beobachtungen bestätigt.

Der Mittelwert und der Median der Fehler nehmen mit steigender Datenmenge ab. Die realisierte Verbesserung ist gering. Das Modell mit dem geringsten Fehlerwert unter allen KNN ist aus einem 5-stündigen Datensatz. Allerdings muss einschränkend festgehalten werden, dass dies ein Resultat des Zufalls ist und gleichzeitig unter den Modellen aus S5 auch das Modell mit dem größten Fehlerwert zu finden ist. Grundsätzlich ist eine große Datenbasis für ein gutes Identifikationsergebnis zu bevorzugen. Die Informationsmenge in kleinen Datensätzen ist in der Tendenz geringer als in großen. Hierbei ist zu beachten, dass die Modellgenauigkeit durch weitere Messungen nicht beliebig steigerbar ist.

Auffällig im Verlauf der RMSE aus Abbildung 6.2b ist der Sprung zwischen S70 und S140. Diese erneute Verbesserung des S140-Modells gegenüber den Modellen der S70-Datensätze fällt überraschend groß aus und spricht gegen die These, dass der Informationszuwachs gering ist. Falls die Datensätze S70 entgegen der Annahme in der Informationsmenge doch stark wachsen, könnte durch die Kombination beider Datensätze zu S140 die Informationsmenge vergrößert werden und so die Modellgenauigkeit zunehmen. Diese Annahme erscheint bei erneuter Analyse der Ergebnisse der Modellbildung (siehe Abbildung 5.7a) unwahrscheinlich. In der Modellbildung ist ein solcher Sprung von S70 auf S140 nicht zu erkennen. Es wird daher vermutet, dass dieses Phänomen auf eine Eigenschaft der Validierungsdaten zurückzuführen ist. In Anbetracht der Verbesserung der Modellgenauigkeit im Verhältnis zum absoluten Fehler ist diese allerdings von geringer Relevanz.

Der Vergleich zwischen ESM und KNN zeigt, dass beide Modellierungsansätze ein sehr ähnliches Verhalten besitzen. Die Streuung des RMSE ist für kleine Datensätze groß und nimmt mit steigender Datenmenge ab. Der resultierende Modellfehler für kleine Datensätze ist offensichtlich stark zufallsabhängig. Der Einfluss des Zufalls kann durch eine steigende Datenmenge limitiert werden. Das Maß der Streuung der verschiedenen Datensätze bestärkt die These, dass der Informationszuwachs mit der Messdauer abnimmt.

Für die Künstlichen Neuronalen Netze zeigt sich eine deutlich größere Streuung für die einzelnen Datensätze im Vergleich zum Einspurmodell (siehe Abbildung 6.2). Dies ist wenig erstaunlich, da beim KNN sämtliches Modellwissen aus den Daten gewonnen wird und nicht wie beim Einspurmodell physikalische Zusammenhänge in der Modellstruktur hinterlegt sind. Unterschiede in den Daten der Identifikation führen zu größeren Abweichungen der Modelle untereinander.

Ein Vergleich mit den Fehlerwerten der KNN zeigt, dass diese für Datensätze geringer Größe deutlich über denen des Einspurmodells liegen. Der Modellfehler des Einspurmodells für Einzelfahrten mit der geringsten Modellgenauigkeit ($\text{RMSE}_{\text{ESM, Einzelfahrt, max}} = 0,2864 \text{ m/s}^2$) liegt auf einem vergleichbaren Niveau wie das schlechteste KNN-Modell basierend auf 20 Std. Fahrdaten ($\text{RMSE}_{\text{KNN, S20, max}} = 0,2813 \text{ m/s}^2$, siehe Tabelle 6.2). Die erreichte Genauigkeit der KNN und ESM ist für S140 auf einem vergleichbaren Niveau. Die Robustheit kann durch große Datensätze verbessert werden, allerdings kann der Median/Mittelwert der Fehlerwerte (siehe Tabelle 6.2) nur minimal gesenkt werden. Trotz grundsätzlich verschiedener Modellierungsansätze kann eine Abweichung von $0,22 \text{ m/s}^2$ für den RMSE nicht unterschritten werden. Der Grund für den RMSE liegt im zufälligen Messfehler der statischen Wankrotation, der in Abschnitt 3.5 beschrieben wird.

Für Modelle aus 20 Std. Fahrdaten können bereits sehr robuste Identifikationsergebnisse erlangt werden. Eine adäquate Datenmenge wird erst mit den S70-Datensätzen erreicht, bei denen die Streuung zwischen den Modellen nur noch minimal ist und eine deutliche Verbesserung nicht weiter erwartet werden kann.

6.2.3 Statistische Fehleranalyse

Die Betrachtung der Fehlermetrik im vorherigen Abschnitt ermöglicht einen Überblick über die Genauigkeit der verschiedenen Modelle. Bei dieser Betrachtung gehen einige Zusammenhänge verloren, sodass im folgenden Abschnitt weitere Analysen folgen. Es werden die Residuen e_k für jeden Zeitschritt im Validierungsmonat analysiert. Stellvertretend für die jeweilige Modellgruppe (Einspurmodelle oder KNN) wird jeweils das Modell des Datensatzes S140 ausgewählt (siehe Tabelle 6.2).

Die Residuen e werden als Häufigkeitsverteilung $H(e)$ in Abbildung 6.3a und 6.4a dargestellt. Die Häufigkeitsverteilung aller Residuen $H(e)$ wird unterteilt in Stillstandzeiten $e_{v_x=0}$ und Residuen $e_{v_x>0}$ während der Fahrt. Eine gemessene Querbewegung $a_{y, \text{sen}}$ resultiert im Stand aus einer Rotation des Aufbaus und/oder aus Messrauschen (siehe Abschnitt 3.5). Stillstandzeiten eignen sich daher sehr gut zur Analyse der Störgröße ϵ_{QD} , die auch während der Fahrt auf den Messwert wirkt.

In einer weiteren Analyse werden Wertepaare aus simulierter Querbeschleunigung $a_{y,k,\text{sim}}$ und gemessener Querbeschleunigung $a_{y,k,\text{sen}}$ für jeden Messzeitschritt k im Validierungsmonat in einem Streudiagramm dargestellt (siehe Abbildung 6.3b und 6.4b). Der Modellwert der Querbeschleunigung $a_{y,k,\text{sim}}$ wird auf der Abszisse, die gemessene Querbeschleunigung $a_{y,k,\text{sen}}$ wird auf der Ordinate abgetragen. Für Werte auf der Referenzlinie gilt, dass $a_{y,k,\text{sim}} = a_{y,k,\text{sen}}$ ist.

Einspurmodell

Die Häufigkeitsverteilungen H des Einspurmodells (Datenbasis S140) für die Validierungsdaten $Z_{V,VM}$ sind in Abbildung 6.3a dargestellt. Die Verteilung der Residuen $H(e)$ ist nicht achsensymmetrisch und hat einen Maximalwert bei $e \approx 0,2 \text{ m/s}^2$. Die Standardabweichung der Verteilung ist $\sigma_e = 0,21 \text{ m/s}^2$. Die Verteilung der Residuen ist näherungsweise auf Werte von $\pm 0,5 \text{ m/s}^2$ begrenzt. Abweichungen oberhalb dieser Grenze sind sehr selten, reichen dann aber bis etwa $\pm 1 \text{ m/s}^2$. Die Verteilung $H(e)$ ist aus zwei Moden zusammengesetzt, die sich gegenseitig überlagern.

In Abschnitt 3.5 wird beschrieben, dass die im Stillstand gemessene Querbeschleunigung $a_{y,\text{sen}}$ durch eine Wankrotation des Sensors entsteht. Diese Rotation wird durch die Modellfreiheitsgrade des Einspurmodells nicht abgebildet und führt zwangsläufig zu einer Abweichung zwischen Sensorwert und Modellwert. Es ist naheliegend, dass die Straßenquerneigung während der Fahrt nicht verschwindet und dass die Störgröße auf den Messwert weiterhin einwirkt. Während der Fahrt überlagern sich Störanteile und Modellfehler und bilden die Residuenwerte aus. Die Fehlerterme im Stillstand dienen also als

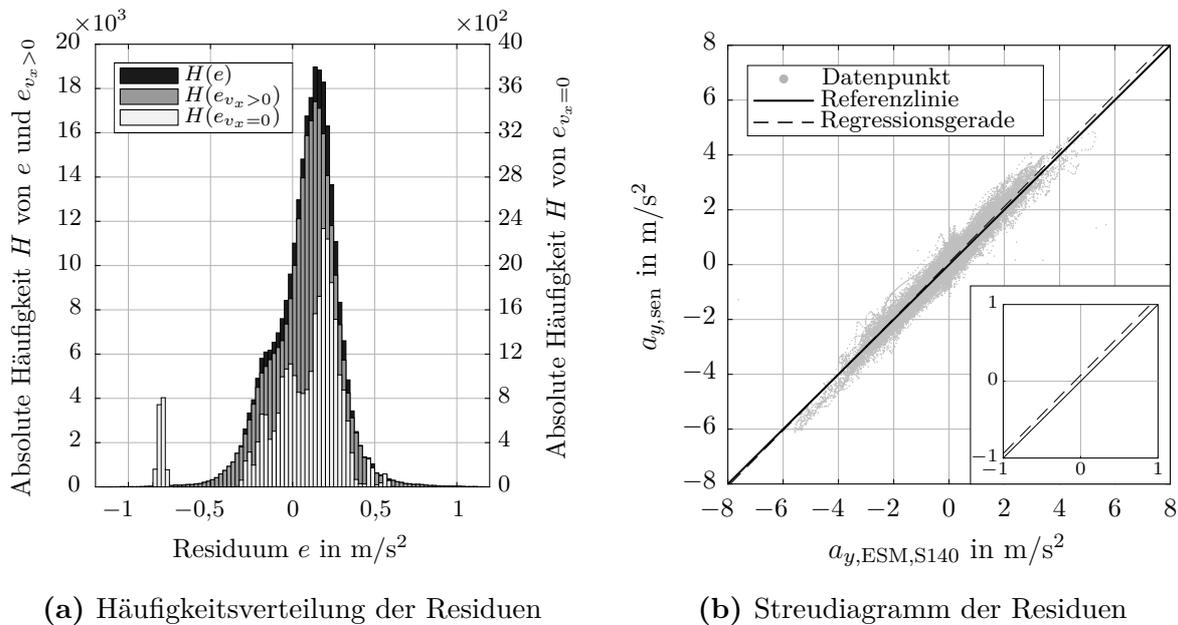


Abbildung 6.3: Einspurmodell: Verteilung der Residuen e für die Daten des Validierungsmonats

Benchmark für den erreichbaren RMSE während der Fahrt. Die Ausgabe des Einspurmodells für $v_x = 0$ km/h ist $a_{y,\text{ESM},S140,v_x=0} = 0$ m/s². Es gilt also, dass $e = a_{y,\text{sen}}$ ist. Die Verteilung der Residuen $H(e_{v_x=0})$ ist gleichzeitig die Verteilung des Messwertes der Querbeschleunigung $H(a_{y,\text{sen}})$. Die Verteilung von $H(e_{v_x=0})$ ähnelt stark der Verteilung der durchschnittlichen Querbeschleunigung im Stillstand (siehe Abbildung 3.7a). Auch für den Validierungsmonat werden maximale Störgrößen von etwa $0,7 - 0,8$ m/s² aufgezeichnet (vergleiche Abschnitt 3.5.2). Die maximalen Störgrößeneinflüsse erschweren die Validierung der Modelle erheblich. Aus Untersuchungen zum Einspurmodell ist bekannt, dass dieses für Fahrsituationen geringer Dynamik zuverlässige Vorhersagen trifft (siehe Abschnitt 5.3). Der Validierungsdatensatz erfüllt die Kriterien des ESM und dennoch werden in der Verteilung $H(e)$ Residuenwerte bis 1 m/s² beobachtet. Diese Abweichung ist im Verhältnis zum Gültigkeitsbereich des Einspurmodells sehr groß und abhängig von der Fahrsituation nicht tolerierbar. Eine Analyse einzelner Fahrsituation folgt daher in Abschnitt 6.2.4.

Ein Vergleich der Residuenverteilung während der Fahrt $H(e_{v_x>0})$ und im Stillstand $H(e_{v_x=0})$ zeigt, dass sich die Verteilungen sehr ähnlich sind. Der RMSE für den gesamten Validierungsmonat ist $\text{RMSE}_{\text{ESM},S140} = 0,2226$ m/s² (siehe Tabelle 6.2). Für Stillstände bzw. während der Fahrt sind der $\text{RMSE}_{\text{ESM},S140,v_x=0} = 0,2883$ m/s² respektive $\text{RMSE}_{\text{ESM},S140,v_x>0} = 0,2149$ m/s². Der Fehlerwert während der Fahrt ist somit kleiner als im Stillstand. Aus der Modellbildung ist bekannt, dass das Einspurmodell Störeinflüsse, wie die Straßenquerneigung, nicht abbilden und kompensieren kann. Daher ist es als positiv zu bewerten, dass die Verteilung $H(e_{v_x>0})$ während der Fahrt, die sich aus Modellfehlern und Störeinflüssen zusammensetzt, der Verteilung von $H(e_{v_x=0})$ für Stillstände stark ähnelt und die Modellfehler somit wahrscheinlich kleiner als die Störeinflüsse sind. Weitere Einblicke in die Verteilung der Residuen, abhängig vom Fahrzustand, ermöglicht das Streudiagramm in Abbildung 6.3b. Aus diesem geht hervor, dass die Residuen größtenteils gleichmäßig um die Referenzlinie streuen. Eine Ausnahme in der Verteilung stellt das Beschleunigungsintervall $a_{y,\text{ESM},S140} = [-6, -4]$ m/s² dar. In diesem Bereich liegen die Residuen einseitig unterhalb der Referenzlinie. Da in diesem Bereich sehr wenige Validierungsdaten existieren und der Gültigkeitsbereich des Einspurmodells verletzt wird, werden diese Datenpunkte nicht weiter betrachtet. Eine Regressionsgerade (gestrichelte Linie) wird durch die Punktwolke gelegt. Die Regressionsgerade besitzt die Geradengleichung $r_{\text{ESM}}(a_{y,\text{ESM},S140}) = 1,02 a_{y,\text{ESM},S140} + 0,08$. Die Steigung der Regressionsgeraden ist höher als die der Referenzlinie, sodass das Residuum zusammen mit der Querbeschleunigung steigt. Ferner ist die Regressionsgerade im Nullpunkt verschoben und weist daher eine statische Abweichung auf. Die Verschiebung auf der Ordinate entsteht durch den verschobenen Datenschwerpunkt der Residuen $(\sum_{k=1}^N e_k)/N = 0,08$ m/s² (vgl. Abbildung 6.3a). Die Ursache für die abweichende Steigung der Regressionsgeraden von der Referenzlinie ist durch eine Limitierung der Modellfreiheitsgrade des Einspurmodells erklärbar. Für steigende Beschleunigungswerte werden die durch die Wankbewegung zusätzlich entstehenden Beschleunigungsterme im Messwert durch das Einspurmodell nicht abgebildet (siehe Abschnitt 3.5). Das Residuum aus sensorisch erfasster Querbeschleunigung und modellierter

Querbeschleunigung nimmt zu. Sowohl die Steigung der Regressionsgeraden als auch die Nullpunktverschiebung können physikalisch plausibel erklärt werden. Zur vollständigen Abbildung dieser Effekte sind weitere Modellfreiheitsgrade und die sensorische Erfassung der Wankrotation notwendig. Die Erfassung zusätzlicher Signale würde allerdings eine Anpassung der Versuchsplanung der NDS notwendig machen. Eine solche Anpassung ist für eine NDS nicht vorgesehen (siehe Abbildung 3.1) und der Prozess müsste erneut durchlaufen werden. Ferner kann festgehalten werden, dass die Residuen der Einspurmodelle auf Störgrößenniveau liegen (vgl. $\text{RMSE}_{\text{ESM},S140,v_x=0} \approx \text{RMSE}_{\text{ESM},S140,v_x>0}$) und folglich die Genauigkeitsgrenze erreicht ist. Grundsätzlich kann das Modell nicht besser werden als die Messauflösung (HEYDINGER, GARROTT et al., 1990).

Künstliches Neuronales Netz

Anders als beim Einspurmodell ist die Modellausgabe des KNNs für Stillstände nicht zwangsläufig 0 m/s^2 , sondern wird basierend auf dem Lenkradwinkel δ_H geschätzt. Die Einflüsse, die auf den Messwert $a_{y,\text{sen}}$ im Stillstand wirken, sind mit dem Lenkradwinkel δ_H nicht vollständig beschreibbar (externe Einflüsse, siehe Abschnitt 3.5), sodass der Fehler für das KNN im Stillstand sehr hoch ist. Der $\text{RMSE}_{\text{KNN},S140,v_x=0}$ ist $0,3263 \text{ m/s}^2$. Der Fehler im Stillstand ist für ein Fahrdynamikmodell von untergeordneter Bedeutung, wengleich der starke Störgrößeneinfluss während der Fahrt weiterhin existiert. Der Fehlerwert des KNNs während der Fahrt ist $\text{RMSE}_{\text{KNN},S140,v_x>0} = 0,2272 \text{ m/s}^2$ und somit deutlich besser als im Stillstand. Im Training der KNN werden deutlich mehr Messpunkte während der Fahrt genutzt als für Stillstände, sodass es nicht überrascht, dass das Netz für diesen Bereich eine höhere Modellgenauigkeit aufweist. Ein weiterer Effekt,

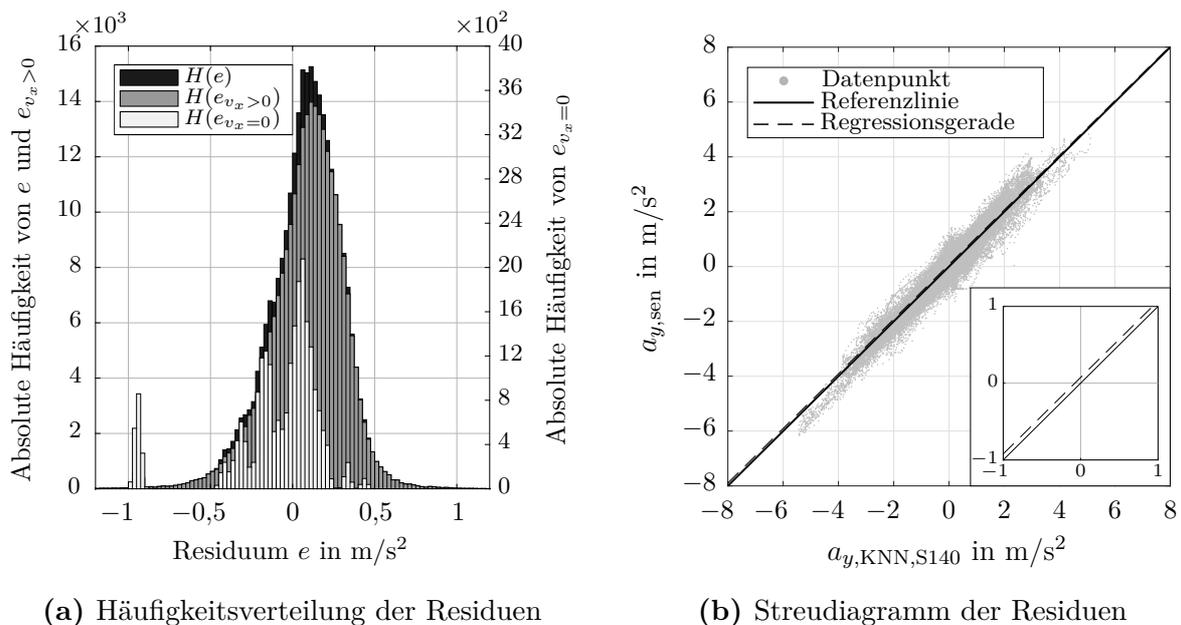


Abbildung 6.4: KNN: Verteilung der Residuen e für die Daten des Validierungsmonats

der sich positiv auf die Modellgüte auswirkt, ist der Schräglaufwinkel, der entsteht, wenn der Versuchsträger auf einer quergeneigten Fahrbahn bewegt wird. Durch den Schräglaufwinkel entsteht eine dynamische Kopplung zur Lenkbewegung und so ein Zusammenhang, der vom Modell erlernt werden kann.

Das Diagramm der Residuenstreuung in Abbildung 6.4b zeigt eine gleichmäßige Verteilung der Datenpunktwolke um die Referenzlinie. Die Regressionsgerade wird mit $r_{\text{KNN}}(a_{y,\text{KNN},S140}) = 0,996 a_{y,\text{KNN},S140} + 0,07$ beschrieben. Die Abweichung in der Steigung der Regressionsgeraden zur Referenz ist minimal. Der Residuumswert ist somit näherungsweise unabhängig von der Querbeschleunigung a_y . Im Umkehrschluss bedeutet dies, dass das KNN die Wankrotation φ_{dyn} infolge einer Kurvenfahrt erlernt und abbildet. Der Nullpunktversatz, der durch den Einfluss der Straßenquerneigung auf den Messwert entsteht, kann durch das KNN nicht korrekt abgebildet werden.

Die Analysen der Genauigkeit von ESM und KNN zeigen, dass die Abweichungen zum Messwert mitunter sehr groß sind. Ursache der Abweichung sind der starke Störgrößeneinfluss. Bei der Bewertung des Störgrößeneinflusses auf die Modellgenauigkeit muss für die beiden Modellarten unterschieden werden.

Das ESM ist durch den fehlenden Modellfreiheitsgrad (Wanken) beschränkt und kann weder die Wankbewegung des Aufbaus noch den Einfluss der Straßenquerneigung abbilden. Ohne eine sensorische Erfassung des Wankwinkels und der Straßenquerneigung ist der Einfluss der Störung nicht ausreichend quantifizierbar und beschreibbar. Die Bewertung der Modellgenauigkeit wird durch die große Unsicherheit des Störgrößeneinflusses erschwert. Eine einfache Auswertung der Residuen ist für die Bewertung der Modelle nicht hinreichend.

Das KNN wiederum verfügt über ausreichend Modellfreiheitsgrade um eine Wankrotation abbilden zu können. Die vorangegangenen Auswertungen zeigen jedoch, dass auch mithilfe von KNN eine vollständige Modellierung aller Effekte auf Basis der gewählten Eingänge nicht gelingt. Die teilweise großen Residuenwerte für KNN resultieren aus einer unvollständigen Auswahl an Systemeingängen. Einige Effekte, wie etwa die Straßenquerneigung, sind über die vorhandenen Eingänge nicht eindeutig beschreibbar. Residuen zwischen Modell und Messsignal sind zwangsläufig die Folge.

6.2.4 Auswertung eines Abschnittes einer Fahrt

Die Analyse der Fehlermetriken und die statistische Auswertung zeigen, dass die identifizierten Modelle den Validierungsdatensatz in großen Teilen gut abbilden. Für weitere Analysen wird ein mehrminütiger Fahrabschnitt aus einer Fahrt des Validierungsdatensatzes untersucht. Bei dem Fahrabschnitt handelt es sich um eine innerstädtische Fahrt im Geschwindigkeitsbereich bis 60 km/h, mit maximalen Querbeschleunigungen bis zur Grenze des linearen Bereichs. In diesem werden einzelne Kurvenereignisse dargestellt und es lassen sich Charakteristika der Modelle beschreiben.

Es wird die Messgröße der Querbeschleunigung $a_{y,\text{sen}}$ mit den Modellwerten der Einspur-

modelle und der KNN verglichen. Hierfür werden die Modelle basierend auf den fünfständigen Datensätzen (S5) und dem vollständigen Datensatz (S140) analysiert. Die 31 Modelle aus den S5-Datensätzen werden als Bereich dargestellt. Die Grenzen sind jeweils der minimale und maximale Wert aus der Modellschar. Der Fahrtabschnitt ist in Abbildung 6.5 für das Einspurmodell und in Abbildung 6.6 für das KNN dargestellt.

Einspurmodell

In Abbildung 6.5 ist die Gegenüberstellung des Messwerts $a_{y, \text{sen}}$ mit den simulierten Werten des Einspurmodells dargestellt. Auf die vier hervorgehobenen und entsprechend nummerierten Bereiche (1.-4.) wird im Folgenden eingegangen. Die optische Überprüfung des Fahrtabschnitts bestätigt die hohe Abbildungsqualität der identifizierten Parametersätze des Einspurmodells (siehe Tabelle 6.2). Zunächst kann festgehalten werden, dass alle Modelle (ein Modell aus S140, 31 Modelle aus S5) den Verlauf der Querbewegung und somit die Dynamik des Versuchsträgers sehr gut beschreiben. Der Signalverlauf des Messwerts weist teilweise eine höhere Dynamik als das ESM auf. Dies kann u. a. durch Messrauschen erklärt werden. Der $\text{RMSE}_{\text{ESM}, \text{S140}} = 0,2030 \text{ m/s}^2$ liegt für diese Fahrt unterhalb des durchschnittlichen Werts des Validierungsdatensatzes (siehe Tabelle 6.2). Der maximale Fehler ist $1,09 \text{ m/s}^2$ zum Zeitpunkt $t = 454 \text{ s}$. Die Signalverläufe der Modellschar sind alle sehr ähnlich und erst bei einer Vergrößerung werden die Unterschiede zwischen den Modellen sichtbar. Die bisherige Beobachtung (siehe Abschnitt 6.2.2), dass mit ausreichend A-priori-Wissen in der Modellbildung (Modellstruktur und Parametergrenzen)

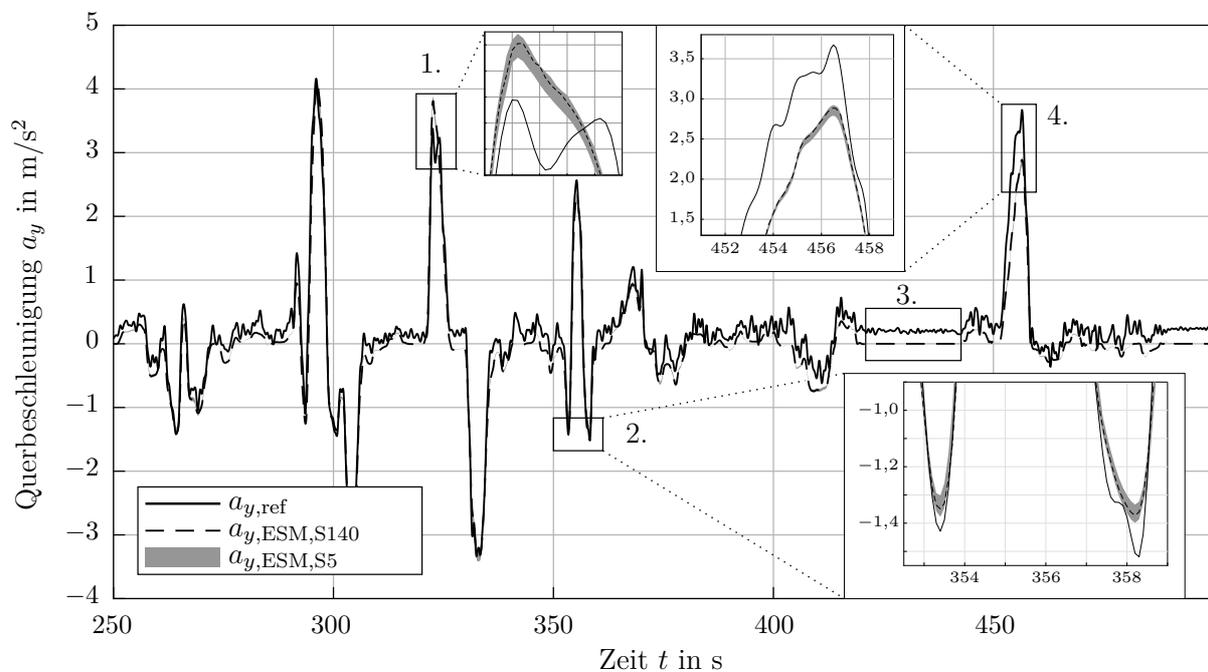


Abbildung 6.5: Einspurmodell: Vergleich der Modellausgabe mit dem aufgezeichneten Messwert für einen mehrminütigen Fahrtausschnitt einer Validierungsfahrt

bereits sehr gute Vorhersagen mit einem kleinen Datensatz getroffen werden können, wird bestätigt. Die Analyse der nummerierten Abschnitte ermöglicht weitere Einblicke.

1. *Abbiegung links 90°, bei 25 km/h*

Der erste Ausschnitt zeigt eine Linkskurve bei moderater Geschwindigkeit. Der Verlauf der Querbeschleunigung wird durch die Modelle valide beschrieben. Abweichungen treten am Scheitelpunkt auf. Der Messgrößenverlauf offenbart einen Abfall mit anschließendem Anstieg, der durch die Modelle nicht abgebildet wird. Ähnliche Schwingungsphänomene im Scheitelpunkt der Querbeschleunigung können im Studiendatensatz $Z_{V,Studie}$ häufiger beobachtet werden. Diese können durch das ESM nicht vollständig beschrieben werden. Für vergleichbare Messwertverläufe der Systemeingänge aus anderen Fahrten können sowohl Querbeschleunigungsverläufe mit und ohne Schwingung am Kurvenscheitelpunkt beobachtet werden. Die Ursache für diese Schwingung kann basierend auf den Messdaten nicht nachvollzogen werden.

2. *Rechts-Links-Rechts-Kombination bei 30 km/h*

In der Detailansicht werden die Rechtskurven in einer Kurvenkombination (Rechts-Links-Rechts) vergrößert dargestellt. Für die erste Kurve ist der Verlauf der Modelle sehr ähnlich zu dem Messverlauf. Bei der zweiten Kurve sind erneut Signalanteile im Verlauf, die durch die Modelle nicht beschrieben werden. So zeigt der Messwertverlauf einen Sattelpunkt zum Zeitpunkt $t \approx 358$ s, den die Modelle nicht abbilden. Ähnlich wie in Ausschnitt 1. ist im Messsignalverlauf ein Schwingungsphänomen, dass durch das ESM nicht abgebildet werden kann. Die Modellverläufe sind in Phase mit dem Messsignal. Die Abweichung von $0,1 \text{ m/s}^2$ im Scheitelpunkt ist für die Anwendung sehr gut und in Anbetracht des Messrauschens und der Störgrößen ausreichend genau.

3. *Stillstand*

Die im Stillstand gemessene Querbeschleunigung ($a_{y,ref} \neq 0 \text{ m/s}^2$) wird durch das Modell nicht korrekt abgebildet. Der Effekt wird in Abschnitt 3.5 beschrieben.

4. *Abbiegefahrt nach Stillstand*

Im 4. Fahrtausschnitt wird eine Abbiegefahrt nach Stillstand gezeigt. Die Abweichung zwischen Messwert und Modellvorhersage ist groß und im Scheitelpunkt der Kurve beträgt sie etwa $0,7 \text{ m/s}^2$. Der maximale Fehler ist $1,09 \text{ m/s}^2$ zum Zeitpunkt $t = 454$ s. Offensichtlich ist das Modell nicht geeignet, diese Fahrsituation korrekt und valide, basierend auf den Validitätsanforderungen aus Abschnitt 6.1, zu beschreiben. Dies ist der einzige Zeitpunkt in der gesamten Fahrt, zu dem die Anforderungen an die Validität nicht erfüllt werden. Es handelt sich bei der betrachteten Fahrsituation nicht um ein hochdynamisches Manöver, sodass das ESM zur Beschreibung dieses geeignet sein sollte (siehe Abschnitt 5.3.2). Da die Abweichung sehr groß und deutlich größer als für die restliche Fahrt ist, wird eine starke Störung zu diesem Zeitpunkt vermutet. Diese These wird durch die Beobachtungen für das KNN im Folgenden gestärkt.

Künstliches Neuronales Netz

In Abbildung 6.6 ist der obige Fahrtabschnitt erneut für das KNN dargestellt. Bereits aus Abschnitt 6.2.2 ist bekannt, dass die Streuung zwischen den Modellen der KNN für die unterschiedlichen Datensätze deutlich größer ist als bei den Einspurmodellen (siehe Abbildung 6.2). Die Breite der Modellstreuung kann Abbildung 6.6 entnommen werden. Die Modellschar der KNN basierend auf 5 Std. Fahrdaten spannt eine optisch gut erkennbare Fläche (grau dargestellt) auf. Trotz großer Streuung zwischen den Modellen wird deutlich, dass auch das schlechteste Modell den Verlauf qualitativ gut abbildet. Der RMSE für den Abschnitt ist für das KNN aus S140 $\text{RMSE}_{\text{KNN},\text{S140}} = 0,2328 \text{ m/s}^2$. Der maximale Fehler im dargestellten Ausschnitt ist zum Zeitpunkt $t = 454 \text{ s}$ und ist $0,99 \text{ m/s}^2$ groß. Der maximale Fehler der gesamten Fahrt ist $1,19 \text{ m/s}^2$. Der Vergleich zwischen Einspurmodell und KNN zeigt auch für den Fahrtabschnitt, dass die fundamental verschiedenen Modellierungsansätze (theoretische und experimentelle Modellbildung) sehr starke Ähnlichkeiten in den Residuen gegenüber dem Messwert aufweisen.

1. Abbiegung links 90° , bei 25 km/h

Der Verlauf der KNN für die Linksabbiegung entspricht dem des Einspurmodells aus Abbildung 6.5. Die Schwingung im Messsignal wird weder durch das Einspurmodell noch durch das KNN korrekt dargestellt. Grundsätzlich kann beobachtet werden, dass das gemessene Signal der Querbeschleunigung stärker schwingt als die Modellsignale. Die Ursache für die gemessene Schwingung kann jedoch nicht eindeu-

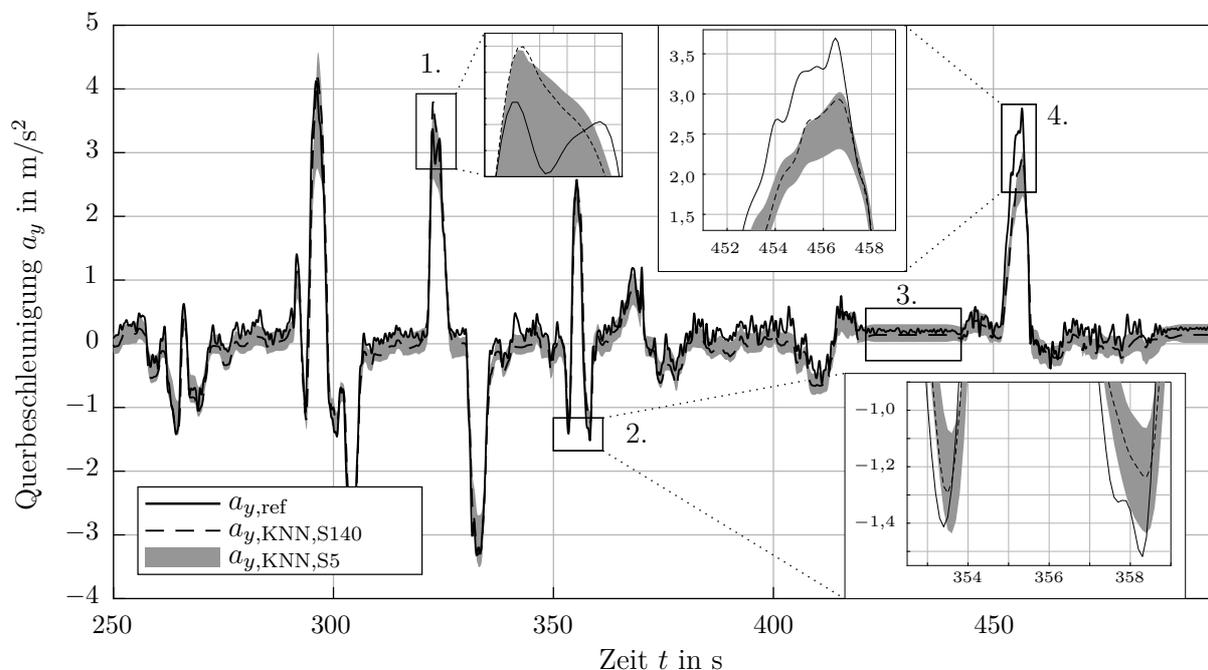


Abbildung 6.6: KNN: Vergleich der Modellausgabe mit dem aufgezeichneten Messwert für einen mehrminütigen Fahrtausschnitt einer Validierungsfahrt

tig benannt werden. Die entstehende Abweichung zwischen Messsignal und Modell liegt innerhalb der definierten Anforderungen.

2. *Rechts-Links-Rechts-Kombination bei 30 km/h*

Die Rechtskurven in der Kurvenkombination (Rechts-Links-Rechts) werden in der Detailansicht vergrößert dargestellt. Für das einzelne KNN aus S140 ist der Verlauf ähnlich zu dem Messverlauf. Die Abweichungen in den Scheitelpunkten liegen bei $0,1 \text{ m/s}^2$ bzw. $0,15 \text{ m/s}^2$. Der Signalverlauf des Modells ist minimal phasenverschoben gegenüber dem Messwert. Der Phasenversatz für die Modellschar liegt bei $0,1\text{-}0,2 \text{ s}$ bzw. $1\text{-}2$ Simulationsschritten. Diese Modelleigenschaft wird in der Validierung für transiente Manöver in Abschnitt 6.5.2 genauer diskutiert. Die Modellschar der KNN aus S5 streut um das Modell von S140. Im Scheitelpunkt weicht das schlechteste Modell etwa $0,4 \text{ m/s}^2$ ab.

3. *Stillstand*

Für Standphasen werden strukturelle Unterschiede der Modellierungsansätze deutlich. Die Modellausgabe des Einspurmodells ist für Geschwindigkeiten von 0 km/h auf $a_{y,\text{ESM}} = 0 \text{ m/s}^2$ festgesetzt. Das KNN erlernt das Verhalten des Versuchsträgers, das durch die Fahrdaten vorgegeben wird. Der Mittelwert aller im Stillstand gemessenen Querbeschleunigungen für die gesamte Fahrstudie beträgt $\bar{a}_{y,\text{sen},v_x=0} = 0,13 \text{ m/s}^2$. Die Modellausgabe des KNNs aus S140 für den markierten Bereich (siehe Abbildung 6.6, 3. Bereich) ist $0,14 \text{ m/s}^2$. Die Modelle der KNN erlernen die durchschnittliche Querbeschleunigung im Stillstand.

4. *Abbiegefahrt nach Stillstand*

Für den Detailausschnitt (4.) sind die Abweichungen zum Messwert groß und die Modelle geben diese Fahrsituation nicht korrekt wieder. Das Verhalten der Modelle (KNN und Einspurmodell) ähneln sich für diese Situation stark, sodass eine zufällige Störung als Ursache für die Abweichung plausibel ist.

Die Analyse des Fahrabschnittes zeigt, dass das ESM und das KNN die Querbeschleunigung grundsätzlich sehr gut abbilden, wenngleich zwei Fehlerphänomene hervorgehoben werden sollen. Zum einen können Schwingungsphänomene im Messsignal (Ausschnitt 1.) beobachtet werden, die durch die Modelle nicht beschrieben werden und zum anderen wird eine Fahrsituation (Ausschnitt 4.) beobachtet, bei der es zu einer großen Abweichung zwischen Messung und den Modellen kommt, deren Ursache unbekannt ist. Obwohl die Modellierungsansätze für ESM und KNN grundsätzlich unterschiedlich sind, weisen beide Modelle ein sehr ähnliches Verhalten auf und weichen vom Messwert in ähnlicher Weise ab. Dies kann als Hinweis interpretiert werden, dass die Abweichung über den Zusammenhang aus Modelleingängen (Geschwindigkeit v_x und Lenkradwinkel δ_H) und Modellausgang (Querbeschleunigung a_y) nicht beschrieben werden kann. Insbesondere die Fahrsituation aus Abschnitt 4. wird als kritisch bewertet, da hier das Residuum besonders groß ist. Residuen dieser Größe sind sehr selten und werden als Ausreißer betrachtet (vgl. Abschnitt 6.2.3). Die Relevanz dieser einzelnen Ausreißer für die Beurteilung

der Modellgüte für alltägliche Fahrten wird als untergeordnet eingestuft. Eine Verbesserung der Modelle für diese Fahrsituationen kann erreicht werden, wenn die Ursache für das Residuum eindeutig beschrieben werden kann. Hierfür sind weitere Messwerte (etwa Wankwinkel, Straßenquerneigung) notwendig.

6.3 Validierung an Referenzsimulation: Stationäre Kreisfahrt

Die bisherige Analyse der Modellgenauigkeit zeigt, dass die identifizierten Modelle das querdynamische Verhalten des Versuchsträgers für alltägliche Fahrten (mit wenigen Ausnahmen) valide abbilden und im Genauigkeitsbereich des zufälligen Fehlerniveaus liegen. Allerdings wird die Analyse durch die Größe des zufälligen Fehlers erschwert. Eine Möglichkeit der Modellvalidierung ohne Störeinflüsse ist die Verwendung eines bereits validierten komplexen Fahrzeugmodells. Dies hat den Vorteil, dass kein Messrauschen und keine äußeren Einflüsse wie Straßenquerneigung, wechselnde Straßenreibung, Wind etc. auf die Referenzdaten einwirken. Besonders zu erwähnen ist hier die Möglichkeit, eine Wankkompensation für die Referenzdaten zu generieren.

Das Referenzmodell⁴⁶ bietet ferner die Möglichkeit, das Verhalten der identifizierten Modelle für Dynamikbereiche zu analysieren, die in alltäglichen Fahrten selten sind. Es wird eine *Stationäre Kreisfahrt* als typisches Manöver zur Analyse des stationären Querdynamikverhaltens gewählt. Das Fahrzeug fährt auf einer Kreisbahn mit einem Radius von 60 m und einer Geschwindigkeit, die bei 10 km/h beginnt und auf 70 km/h ansteigt (ISO 4138). Der Lenkradwinkel wird so geregelt, dass das Fahrzeug auf der Kreisbahn bleibt. Ein konstanter Radius mit zunehmender Geschwindigkeit führt so zu einer zunehmenden Querbeschleunigung $a_{y,dyn}$ (horizontierte Querbeschleunigung, siehe Abschnitt 3.5). Das Referenzmanöver lässt Querbeschleunigungen $a_{y,dyn,ref}$ bis zur Haftgrenze des Reifens, bei etwa 8 m/s^2 , zu. Höhere Beschleunigungen sind für einen normalen Pkw unter normalen Bedingungen nicht zu erwarten (siehe Abschnitt 4.2.2).

Die Abbildungen 6.7 und 6.8 zeigen einen Vergleich des Referenzmodells und des Einspurmodells bzw. des KNNs für verschiedene Datensätze (S5, S20, S70, S140). In den Abbildungen ist zusätzlich die Streuung dargestellt, die die identifizierten Modelle aufweisen. Die Abbildungen enthalten den Medianwert der Modellschar sowie das Minimum und Maximum für einen bestimmten Datensatz. In Ergänzung zu den Messgrößenverläufen werden die Quantile der Querbeschleunigung $|a_y|$ der Fahrdaten eingezeichnet. Die Quantile können Tabelle 5.1 (Zeile: Alle Fahrten) entnommen werden. Die Modelle werden mit dem Ford-Referenzmodell (durchgezogene Linie) verglichen. Diese Referenz zeigt den typischen Verlauf für den Lenk(rad)winkel δ_H über der Querbeschleunigung a_y . Er steigt linear bis zu etwa 4 m/s^2 an. Im Anschluss ist der Verlauf nichtlinear. Der Zusammenhang von Fahrzeuggeschwindigkeit v_x und Fahrzeugquerbeschleunigung a_y ist quadratisch.

⁴⁶Validiertes ADAMS/Chassis-Modell eines Ford C-Max Diesel 2.0 l, bereitgestellt durch die Ford-Werke GmbH

Einspurmodell

In Abbildung 6.7 sind die Verläufe für die verschiedenen Parametersätze des Linearen Einspurmodells dargestellt. Aus Symmetriegründen wird auf eine Unterscheidung zwischen Rechts- und Linkskurven für die Analyse des Einspurmodells verzichtet. Das Fahrzeugverhalten auf einer stationären Kreisfahrt wird maßgeblich durch den Eigenlenkgradienten des Fahrzeugs/Simulationsmodells vorgegeben. Die Datensätze von jeweils 5 Std. haben bei der Analyse des Eigenlenkgradienten (siehe Abbildung 5.5) eine recht große Streuung

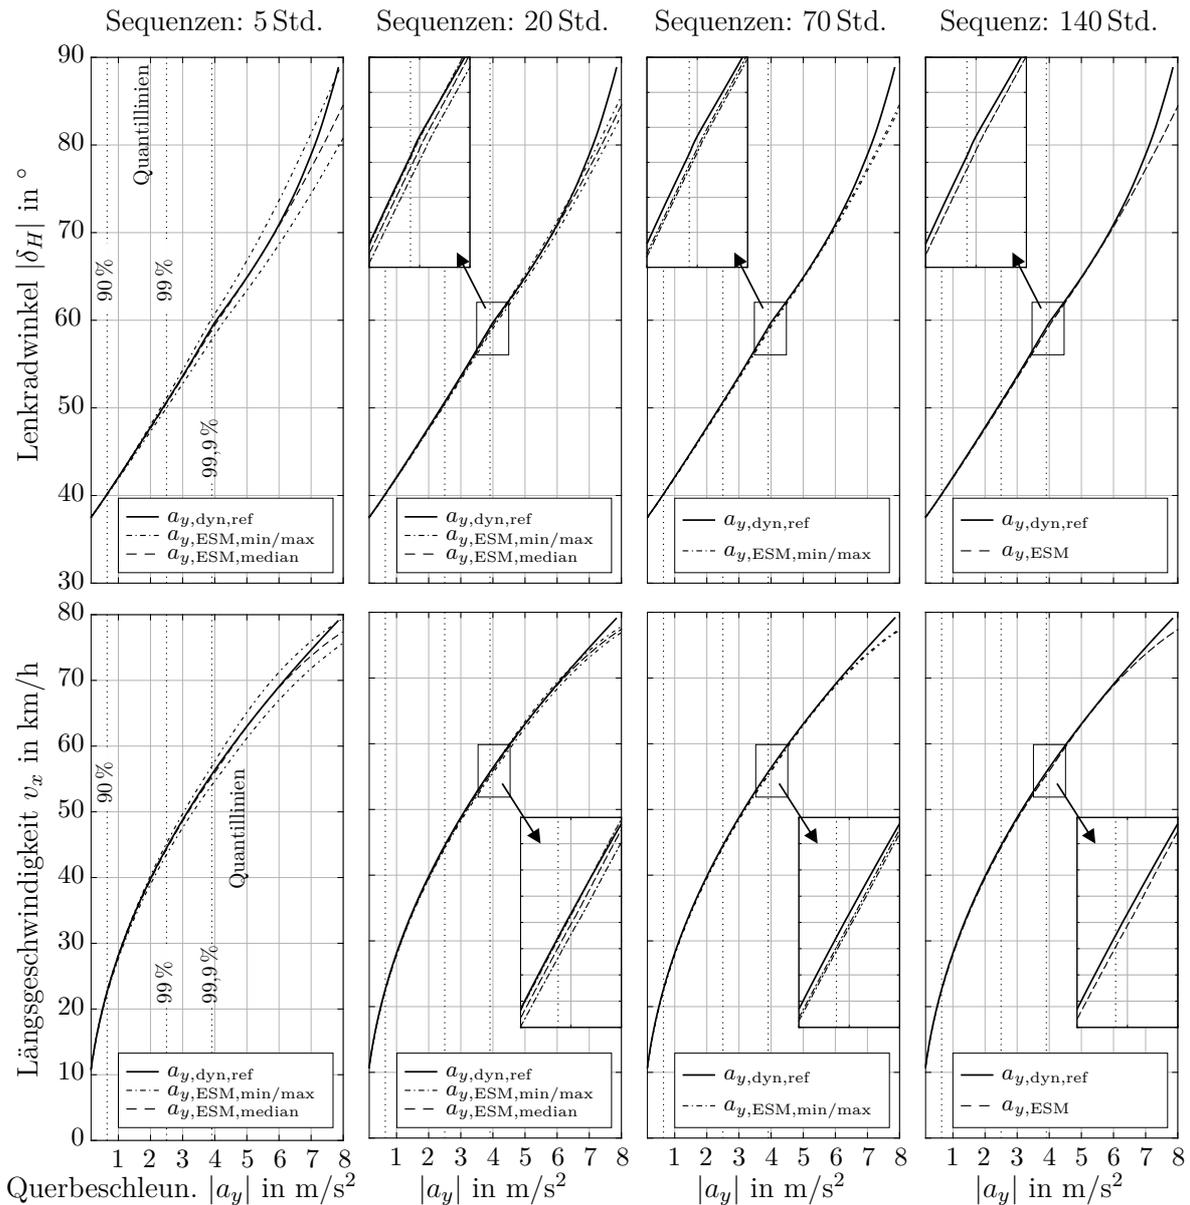


Abbildung 6.7: Einspurmodell: Vergleich einer Referenzsimulation eines Ford C-Max 2.0 l mit den identifizierten Einspurmodellen unterschiedlicher Datensätze für eine stationäre Kreisfahrt

gezeigt. Der Vergleich mit dem Referenzmodell zeigt jedoch, dass geringe Querschleunigungen bereits auf Basis der S5-Datensätze relativ gut beschrieben werden. Es gibt wenig Streuung für Beschleunigungen unter 2 m/s^2 und der Median stimmt mit dem Referenzmodell für diesen Beschleunigungsbereich überein. Höhere Beschleunigungen verursachen dann eine höhere Streuung. Um genügend Daten für diesen Bereich zu sammeln, werden längere Messzeiten benötigt. Die Analyse der adäquaten Datenmenge aus Abschnitt 4.3 empfiehlt eine Messdauer von mehr als 20 Stunden. Die S20-Messreihen führen bereits zu einer sehr guten Darstellung des Referenzmodells. Die geringe Abweichung für hohe Beschleunigungen resultieren zum einen aus wenigen Daten für hohe Beschleunigungen und zum anderen aus der Tatsache, dass das verwendete Einspurmodell höhere Beschleunigungen nicht korrekt beschreiben kann. Effekte aus Nichtlinearitäten und erhöhten Wankwinkeln werden für diesen Dynamikbereich wichtig. Die S70-Datensätze verringern die Streuung der Modelle. Die Genauigkeit gegenüber dem Referenzmodell scheint jedoch nicht wesentlich verbessert zu werden. Die Abweichungen zwischen Referenzsimulation und den Modellverläufen für Sequenzlängen über 70 Std. sind erst in der Vergrößerung zu erkennen und minimal. Die Modelle aus S70 und S140 sind optisch kaum zu unterscheiden. (REICHERTS, HESSE et al., 2021)

Das Eigenlenkverhalten wird für einen Großteil täglicher Fahrten (99,9 %-Quantil) von allen identifizierten Parametersätzen abgebildet. Für Beschleunigungen oberhalb des 99,9 %-Quantils wird die Streuung der Modelle der S5-Datensätze deutlich. Die restlichen Modelle zeigen im gesamten linearen Bereich bis $|a_y| \leq 4\text{ m/s}^2$ sehr hohe Modellqualität. Das zugrunde liegende Eigenlenkverhalten des Versuchsträgers wird durch die identifizierten Parametersätze in Kombination mit dem Einspurmodell sehr gut abgebildet.

Künstliches Neuronales Netz

In Abbildung 6.8 sind die Modellverläufe der KNN für unterschiedliche Datenmengen dargestellt. Für KNN wird symmetrisches Verhalten für positive und negative Lenkwinkel (Links- und Rechtskurven) nicht durch die Modellstruktur vorgegeben, sondern muss erlernt werden. In Abbildung 6.8 werden die Modellverläufe für Rechtskurven dargestellt. Zusätzlich werden für die Modelle aus S70 und S140 auch die Modellverläufe für Linkskurven ausgewertet (dargestellt als Strich-Punkt-Punkt-Linie).

Die große Streuung für kleine Datensätze (S5) wird auch im stationären Fahrmanöver deutlich. Für Beschleunigungswerte oberhalb des 99 %-Quantils geht der Bereich der minimalen und maximalen Modellwerte stark auseinander. Eine Vorhersage ist nicht für alle Modelle der Modellschar valide. Abermals zeigt sich die starke Abhängigkeit der experimentellen Modelle von der Datenmenge. Speziell für kleine Datensätze sind im Dynamikbereich oberhalb des 99 %-Quantils nicht ausreichend Informationen vorhanden. Für größere Datensätze (20 Std. und 70 Std.) wird die Streuung für Beschleunigungen oberhalb des 99 %-Quantils deutlich kleiner und die Modellvorhersagen robuster.

Die Modellgenauigkeit steigt mit der Datenmenge und die Verläufe der beiden 70-Std.-Datensätze sind sich sehr ähnlich. Das Modell aus 140 Std. Fahrdaten besitzt die höchste

Genauigkeit. Der lineare Zusammenhang aus Lenkradwinkel δ_H und Querbeschleunigung a_y im Bereich $|a_y| \leq 4 \text{ m/s}^2$ wird durch die KNN allerdings nur näherungsweise linear abgebildet. Die Auswertung der verschiedenen Modelle aus Abbildung 6.8 zeigt, dass die Signalverläufe teilweise mehrere Schnittpunkte mit dem Referenzverlauf besitzen.

Die Analyse der Linkskurven der Modelle aus den Datensätzen S70 zeigt näherungsweise symmetrisches Modellverhalten. Das Modellverhalten aus S140 weist stark asymmetrisches Verhalten auf. Das Verhalten für Linkskurven weicht für Beschleunigungen oberhalb 3 m/s^2 stark von der Referenzlinie ab. Die fehlende Symmetrie kann durch die starke

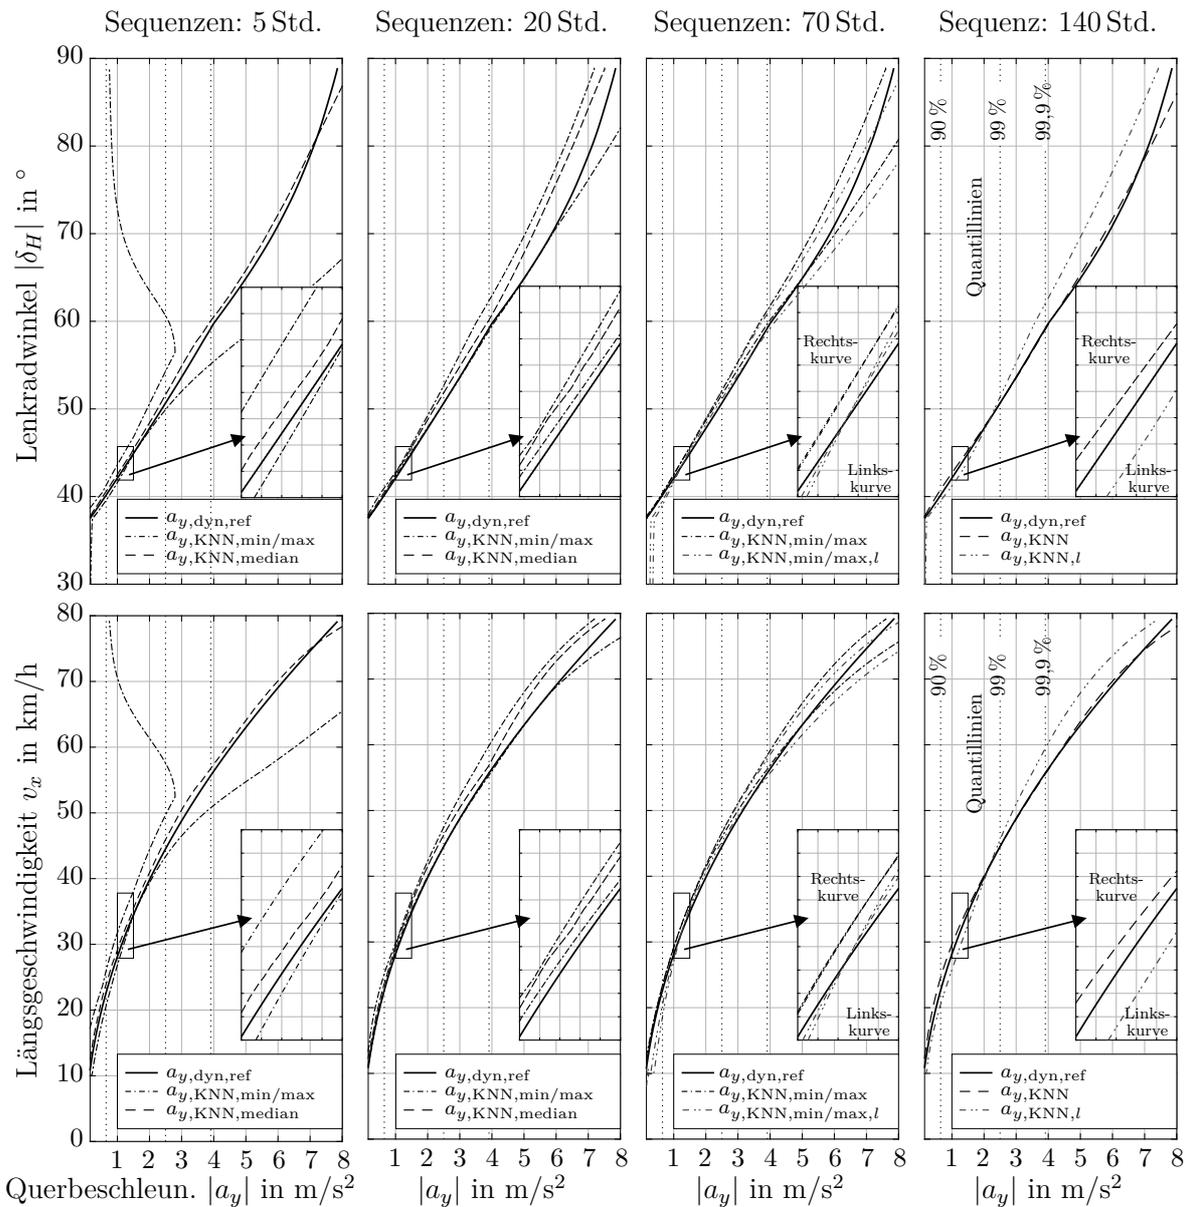


Abbildung 6.8: KNN: Vergleich einer Referenzsimulation eines Ford C-Max 2.0 l mit den identifizierten KNN unterschiedlicher Datensätze für eine stationäre Kreisfahrt

Asymmetrie in den Beschleunigungsdaten begründet werden (siehe Symmetrieachse in Abbildung 4.6b). Die Störung der Straßenquerneigung wirkt sich asymmetrisch für Links- und Rechtskurven aus (siehe Abschnitt 3.5.1). Die erlernte mittlere Straßenquerneigung (siehe Abschnitt 6.2.4) verursacht eine Nullpunktverschiebung der Verläufe.

Ein weiterer Effekt, der bei der Modellbildung beachtet werden muss, ist der Umstand, dass häufig höhere Querbeschleunigungen für Rechtskurven gemessen wurden (siehe Abbildung 4.6b). Dies ist mit dem in Deutschland geltenden Rechtsverkehr zu begründen. In der Folge sind Autobahnauffahrten und -abfahrten häufig Rechtskurven und bilden somit auch die Mehrheit der Kurvenfahrten mit hohen Geschwindigkeiten und Querbeschleunigungen. Die Asymmetrie in der Störung in Kombination mit der Übergewichtung⁴⁷ von Rechts- zu Linkskurven beeinflussen die Modellbildung und haben Einfluss die Modellausgaben für Rechtskurven und Linkskurven.

Nachweis der Funktionalität einer NDS für die Identifikation

Die Validierung basierend auf naturalistischen Fahrdaten und der stationären Kreisfahrt zeigt, dass die Identifikation der Querdynamik grundsätzlich gelingt. Der Nachweis, dass NDS für Identifikationszwecke genutzt werden kann, ist erbracht. Die Validierungsanforderungen werden von den unterschiedlichen Modellen zu großen Teilen erfüllt. Die Menge der Datenbasis ist bei der Validität der Modelle und deren Genauigkeit ein ausschlaggebender Faktor.

- Für das theoretische Modell kann ein Parametersatz gefunden werden, der das dynamische Verhalten beschreibt und das Eigenlenkverhalten wird im linearen Bereich valide identifiziert. Die Genauigkeit des Modells ist im Mittel hinreichend gut, um im geforderten Genauigkeitsbereich zu liegen. Allerdings werden für einzelne Fahrsituationen die Anforderungen verletzt. Dies wird auf Störungen der Messgröße zurückgeführt. Der Nachweis, dass die Identifikation der Querdynamik basierend auf physikalischen Modellparametern gelingt und ausreichend Informationen zum querdynamischen Verhalten im Datensatz vorliegen, wird somit dennoch als erbracht verstanden, obwohl in einzelnen Fahrsituationen die Validierungsziele nicht erreicht werden.
- Die Validität der KNN ist eingeschränkt. Die Modellgenauigkeit streut zwischen den Modellen stark und ist insbesondere von der Datensatzgröße abhängig, sodass Modelle basierend auf den Datensätzen S5 teilweise sehr große Modellfehler erzeugen. Die Modelle S70 und S140 erfüllen die geforderte Genauigkeit für alltägliche Fahrten und können für diese Anforderung als valide betrachtet werden.
Die Analyse der stationären Kreisfahrt zeigt, dass ein symmetrisches Kurvenverhalten nur eingeschränkt von KNN erlernt und das Eigenlenkverhalten im linearen Be-

⁴⁷Das Wissen über die Versuchsträgersymmetrie hätte in die Modellbildung einfließen können. Eine Möglichkeit ist die nachträgliche Aufbereitung der Daten für gleiches Verhalten in Rechts- wie Linkskurven. Da ein solcher Ansatz auf A-priori-Wissen basiert und dieses ausdrücklich nicht verwendet werden soll, wurde dieser Ansatz nicht weiter untersucht.

reich nicht vollständig korrekt abgebildet wird. Es kann jedoch festgehalten werden, dass die Modellvorhersagen qualitativ sinnvoll sind und die Modelle mit Datenmengen über 20 Std. Fahrdaten plausible Ausgaben erzeugen. Die erreichte Genauigkeit wird als starkes Indiz gewertet, dass die Identifikation der Querdynamik auch ohne A-priori-Wissen gelingen kann. Zur weiteren Steigerung der Modellgenauigkeit werden die Daten balanciert (siehe Abschnitt 5.4.2).

6.4 Validierung der KNN mit balancierter Datenbasis

In Abschnitt 5.2 werden die möglichen Auswirkungen der Messwertverteilung auf das Identifikationsergebnis diskutiert. Eine Methode zur Segmentierung und Beeinflussung der Messwertverteilung in den Daten wird in Abschnitt 5.2.1 vorgestellt. In Abschnitt 5.4.2 wird beschrieben, wie der balancierte Datensatz erstellt wird. In der bisherigen Validierung werden die Identifikationsergebnisse der vollständigen Datensätze analysiert. Für die Parameteridentifikation des Einspurmodells wird, aus den in Abschnitt 5.3.3 diskutierten Gründen, auf eine Identifikation mit balancierten Daten verzichtet. Die Modelle der balancierten Künstlichen Neuronalen Netze (Abk.: bKNN) werden im folgenden Abschnitt diskutiert. Es werden die bekannten Validierungsmethoden in komprimierter Form dargestellt und es wird auf Besonderheiten der bKNN eingegangen.

6.4.1 Validierungsmonat: Fehlermetrik

Die Auswertung der Fehlermetriken für das bKNN ist in Tabelle 6.3 dargestellt. Das Vorgehen bei der Auswertung folgt der Beschreibung aus Abschnitt 6.2.2. Die Streuung für kleine Datensätze (S5) ist für den RMSE sehr groß und deutlich größer als für das KNN aus Tabelle 6.2. Die geringe Modellgenauigkeit einzelner bKNN aus S5 ist wenig überraschend. Aus der bisherigen Validierung ist bereits bekannt, dass der Datenumfang der S5-Datensätze für eine valide Modellbildung zu gering ist. Bei der Balancierung der Datensätze werden weitere Daten aus den Datensätzen entfernt, sodass der Informationsinhalt tendenziell weiter abnimmt. Eine Verbesserung der Modellgenauigkeit der bKNN

Tabelle 6.3: Fehlermetriken des Validierungsmonats $Z_{V,VM}$ der bKNN mit balancierten Daten

	RMSE in m/s^2			
	min	max	Median	Mittel
S140	0,2370			
S70	0,2392	0,2426	–	0,2409
S20	0,2252	0,2490	0,2412	0,2402
S5	0,2228	0,5122	0,2577	0,2775

gegenüber den KNN ist für Datensätze mit mehr als 20 Std. Fahrdaten zu beobachten. Für die größeren Datensätze ab S20 weisen die bKNN sowohl eine bessere mittlere Genauigkeit (geringe RMSE) als auch eine geringere Streuung zwischen den Modellen der Datensätze auf. Eine Balancierung der Daten erscheint basierend auf der Fehlermetrik durchaus sinnvoll zu sein, wenngleich die Verbesserung der Fehlerwerte nur minimal ist. Die Modellgenauigkeit wird weiterhin durch den starken Einfluss der Störgrößen limitiert.

6.4.2 Validierung an Referenzsimulation: Stationäre Kreisfahrt

Die Auswertung der Manöversimulation der stationären Kreisfahrt⁴⁸ für die bKNN ist in Abbildung 6.9 dargestellt. Die Varianz liegt deutlich über den Fehlermetriken der Vergleichsmodelle aus Tabelle 6.2. Eine Gegenüberstellung mit dem Referenzmodell zeigt, dass geringe Querbeschleunigungen bereits auf Basis der S5-Datensätze relativ gut beschrieben werden. Die Varianz für Beschleunigungen unter 2 m/s^2 ist gering. Für höhere Querbeschleunigungen nehmen die Varianz und der Modellfehler zu. Der Median der bKNN scheint mit dem Referenzmodell für den linearen Beschleunigungsbereich übereinzustimmen. Für die Modelle der S20-Datensätze kann die Streuung verringert werden. Im linearen Bereich bis 4 m/s^2 sind Abweichungen zwischen der Referenzlinie und den Modellen kaum zu erkennen. Die S70-Datensätze verringern die Streuung der Modelle abermals. Die Streuung im nichtlinearen Beschleunigungsbereich nimmt weiter ab. Das Modellverhalten für Links- bzw. Rechtskurven ist näherungsweise symmetrisch. Ein ähnliches Verhalten kann für das bKNN aus S140 beobachtet werden. Im 99,9%-Quantil wird die Referenz sowohl für Links- als auch für Rechtskurven sehr gut abgebildet. Für eine größere Querbeschleunigung nimmt die Streuung zwischen den Modellen zu. Ein vollständig symmetrisches Modellverhalten ist aufgrund der Datenbasis nicht zu erwarten. Die Analyse der bKNN zeigt eine deutliche Steigerung der Modellgenauigkeit für die stationäre Kreisfahrt gegenüber den KNN aus Abbildung 6.8 für den gesamten Querdynamikbereich.

Nachweis der Funktionalität von NDS für die Identifikation ohne A-priori-Wissen

In Abschnitt 6.2 wird gezeigt, dass die KNN sehr hohe Genauigkeiten für naturalistische Fahrten besitzen. Allerdings wird das Eigenlenkverhalten nur eingeschränkt erlernt, wie die Analyse der stationären Kreisfahrt zeigt (siehe Abbildung 6.8). Durch die Balancierung der Daten kann die Genauigkeit für naturalistische Fahrten minimal verbessert werden. Eine deutliche Verbesserung der Modellgenauigkeit kann für das Eigenlenkverhalten beobachtet werden. Die bKNN weisen eine verbesserte Symmetrie für Links- und Rechtskurven auf, dies führt zu einem geringeren Modellfehler.

⁴⁸Informationen zur Durchführung der Simulation können Abschnitt 6.3 entnommen werden.

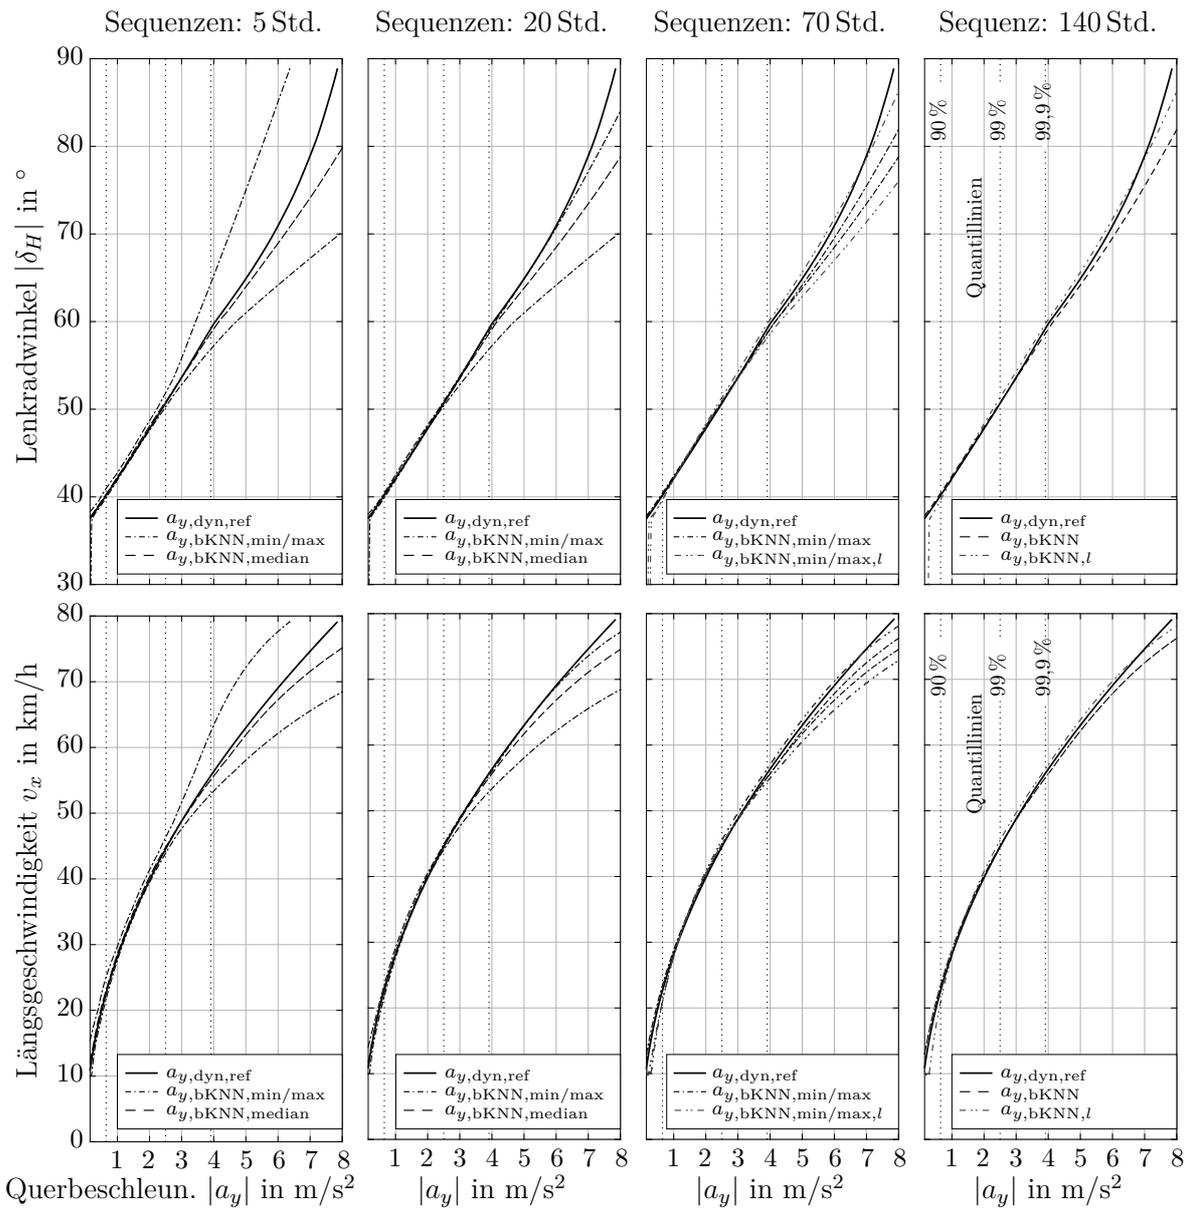


Abbildung 6.9: KNN mit balancierten Daten: Vergleich einer Referenzsimulation eines Ford C-Max 2.0 l mit den identifizierten bKNN unterschiedlicher Datensätze für eine stationäre Kreisfahrt

Die Validierungsanforderungen werden mit den bKNN erfüllt und die Modelle sind hinreichend genau. Der Nachweis, dass die Identifikation der Querdynamik basierend auf NDS-Daten auch ohne A-priori-Wissen⁴⁹ möglich ist, kann somit erbracht werden.

⁴⁹A-priori-Wissen wird in diesem Zusammenhang so verstanden, dass kein Expertenwissen hinsichtlich einer geeigneten Anregung (wie etwa bei Fährmanövern) für die Datenauswahl genutzt wird. Die Segmentierung hat das Ziel, den Datensatz zu balancieren (siehe Abschnitt 5.2). Hierfür wird eine einfache Regel angewandt, die kein Expertenwissen voraussetzt. Das Verhältnis von Geradeausfahrten zu Kurvenfahrten wurde experimentell ermittelt.

6.5 Validierung seltener Fahrereignisse

Die Validität der Modelle für die gestellten Anforderungen aus Abschnitt 6.1 wird in den vorherigen Abschnitten erbracht. Eine Untersuchung der Modellgenauigkeit über die geforderten Anforderungen hinaus kann weitere Potentiale dokumentieren. Daher wird ferner die Modellgenauigkeit für seltene oder extreme Fahrereignisse untersucht. Die Häufigkeit von Messwerten mit hohen Beschleunigungen oder transienten Zuständen ist in alltäglichen Fahrten sehr gering. Eine hohe Modellgenauigkeit ist für diese Zustände per se also nicht zu erwarten. Gänzlich auszuschließen sind solche Ereignisse dennoch nicht. Wie hoch die Modellgenauigkeit für seltene Fahrereignisse ist, wird im Folgenden untersucht. Da die gesuchten Fahrdaten im regulären Validierungsdatensatz (Normalbetrieb des Fahrzeugs) äußerst selten sind, kommen speziell hierfür erhobene Daten zum Einsatz.

6.5.1 Validierung hoher Querbeschleunigungen

In den Fahrdaten sind Querbeschleunigungswerte oberhalb von 5 m/s^2 besonders selten. Etwa 99,9% der Fahrdaten weisen eine Beschleunigung unter $|a_y| < 5 \text{ m/s}^2$ auf. Zur Untersuchung des 0,1%-Quantils sind somit Fahrmanöver mit hoher Querbeschleunigung notwendig. Sollen gezielt Daten mit hohen Querbeschleunigungen im regulären Straßenverkehr aufgenommen werden, so scheint es ratsam, eine sehr kontrollierbare Umgebung zu wählen. Autobahnauffahrten oder -kreuze eignen sich hierzu, da hier sowohl Gegenverkehr als auch Fußgänger ausgeschlossen sind. Außerdem steht die Kombination aus Straßenkrümmung und erlaubten Geschwindigkeiten in einem Verhältnis, das eben die gewünschten Querbeschleunigungen erlaubt. Die zusätzlichen Validierungsdaten bilden das mehrfache (2,5-fache) Durchfahren eines Autobahnkreuzes im Duisburger Süden ab und erfüllen die Forderungen hinsichtlich der maximal auftretenden Beschleunigungen. Der Verlauf der Querbeschleunigung, eine Gegenüberstellung der verschiedenen Signalverläufe für einen Teilabschnitt (Kurvenkombination A) sowie eine Skizze des Autobahnkreuzes sind in Abbildung 6.10 dargestellt.

Zur Validierung hochdynamischer Kurvenfahrten werden die verschiedenen Modelle (ESM, KNN und bKNN) basierend auf dem Datensatz S140 analysiert. Der RMSE für das gesamte Manöver im Zeitintervall $t = [870 \text{ s}, 1200 \text{ s}]$ ist

- für das Einspurmodell: $\text{RMSE}_{\text{ESM},\text{S140}} = 0,4443 \text{ m/s}^2$,
- für das KNN: $\text{RMSE}_{\text{KNN},\text{S140}} = 0,6048 \text{ m/s}^2$ und
- für das bKNN: $\text{RMSE}_{\text{bKNN},\text{S140}} = 0,3770 \text{ m/s}^2$.

Das balancierte Modell eignet sich offenbar am besten zur Abbildung hochdynamischer Manöver. Auch in der Vergrößerung zeigt sich, dass das bKNN den Messwertverlauf deutlich besser abbildet als das KNN oder das Einspurmodell. Das Einspurmodell ist für den untersuchten Dynamikbereich nicht ausgelegt und die Modellannahmen nicht weiter gültig. Eine hohe Modellgenauigkeit ist folglich nicht zu erwarten. Zusätzlich steigt für hohe

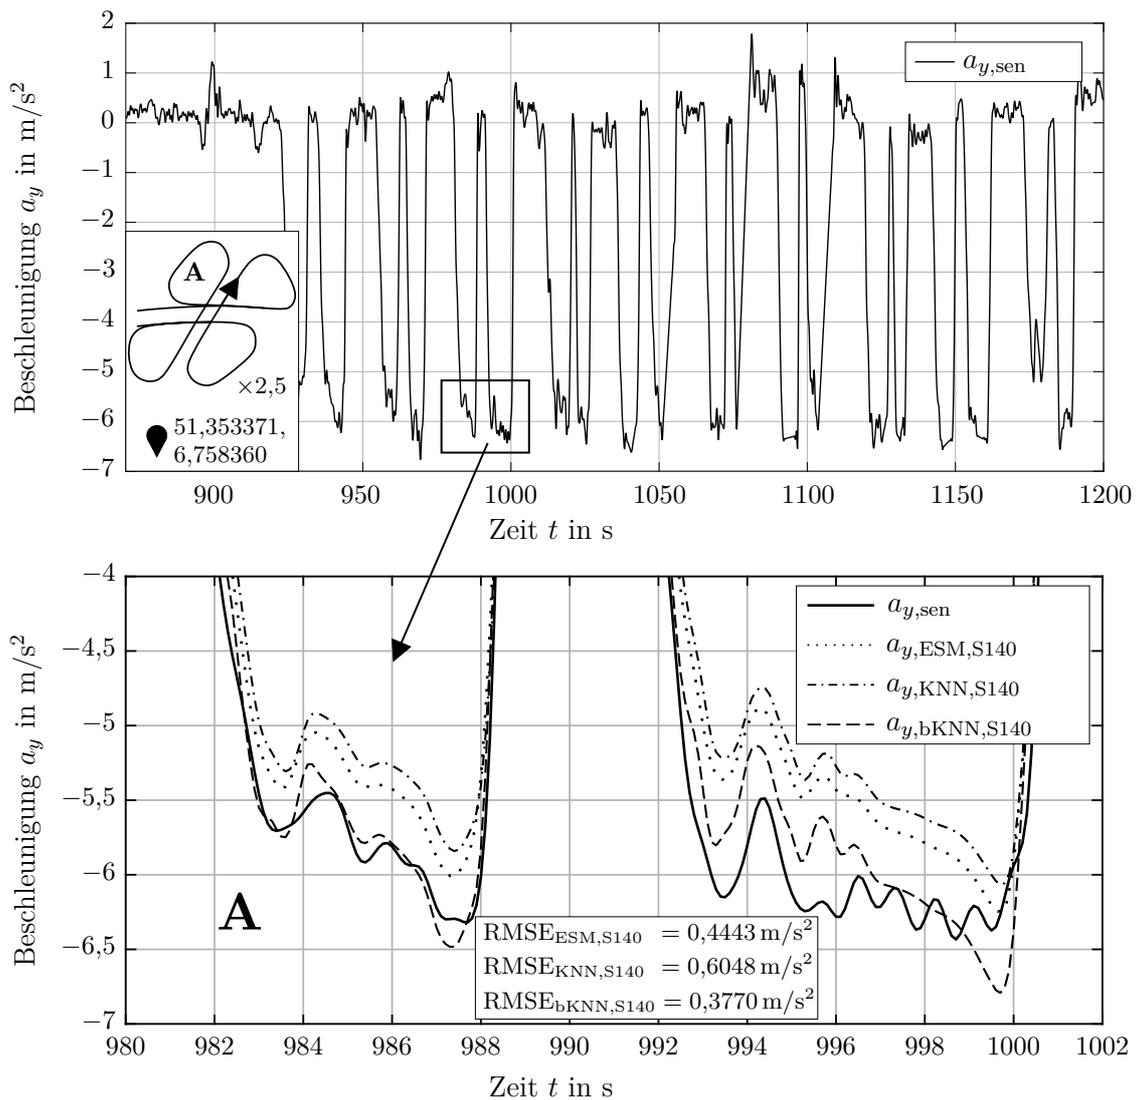


Abbildung 6.10: Modellvergleich für hochdynamische Kurvenfahrten beim Durchfahren eines Autobahnkreuzes

Querbeschleunigungen $a_{y,dyn}$ der Einfluss der Wankbewegung auf den Messwert $a_{y,sen}$. Dieser kann vom Einspurmodell strukturell nicht abgebildet werden. Das KNN ist für das untersuchte Szenario am schlechtesten geeignet. Im Gegensatz zum Einspurmodell ist die geringe Modellgenauigkeit nicht durch zu wenige Freiheitsgrade, sondern durch die Messgrößenverteilung in den Trainingsdaten zu erklären. Eine Anpassung der Verteilungen in den Daten, wie es bei den bKNN der Fall ist, zeigt für hochdynamische Fahrten eine sehr hohe Modellgenauigkeit. Das Vorhaben, seltene Fahrereignisse durch balancierte Daten besser abzubilden, kann für den untersuchten Validierungsdatensatz durch die Segmentierung und Balancierung der Fahrtdaten (wie in Abschnitt 5.2 und 5.4.2 beschrieben) erreicht werden.

6.5.2 Validierung transienten Verhaltens

Ein Ausweichmanöver, wie es in Ausnahmefällen auch im öffentlichen Verkehr vorkommt, ist in ISO 3888-1 als *Doppelter Spurwechsel* definiert. Dieses sehr realitätsnahe Fahrmanöver regt transiente Fahrzustände an und eignet sich daher sehr gut, um das Modellverhalten etwa für sicherheitskritische Fahrereignisse zu untersuchen. Aus Sicherheitsgründen kann ein solches Manöver im öffentlichen Verkehr nicht gezielt eingefahren werden. Daher wird bei der Validierung auf Simulationsdaten zurückgegriffen.

Doppelter Spurwechsel

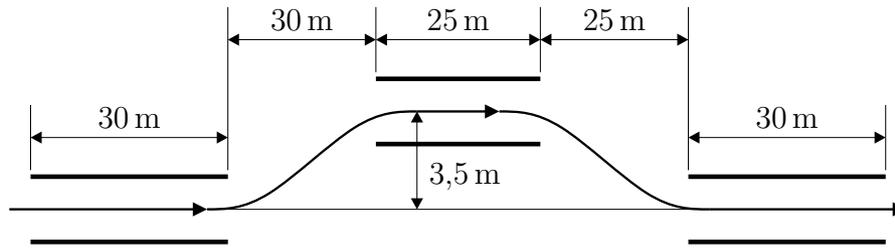
Der doppelte Spurwechsel simuliert ein Ausweichmanöver bei hoher Geschwindigkeit im geschlossenen Regelkreis (Closed-Loop, siehe Abschnitt 2.2.4). Hierbei muss der Fahrzeugführer den Versuchsträger von seiner Fahrspur auf eine parallel verlaufende Fahrspur manövrieren und im Anschluss wieder auf die ursprüngliche Fahrspur zurückwechseln, ohne dabei eine vorgegebene Fahrspurbegrenzung zu überschreiten. Der Aufbau des Parcours ist in Abbildung 6.11a dargestellt. Als Referenz dient erneut das validierte ADAMS/Chassis-Modell eines Ford C-Max Diesel 2.0 l⁵⁰, das auch in Abschnitt 6.3 verwendet wird. In der Manöverspezifikation sind verschiedene Varianten definiert. Das vorliegende Manöver wird mit einer auf 100 km/h festgelegten Fahrzeuggeschwindigkeit v_x durchgeführt. Die Geschwindigkeit ist hierbei bis auf 0,1 km/h konstant. In Abbildung 6.11b sind die Signalverläufe der horizontalen Querbeschleunigung $a_{y,dyn}$, des Lenkradwinkels δ_H und des Wankwinkels φ_{dyn} für das Manöver dargestellt. Zum Manövrieren durch den Parcours sind schnelle und starke Lenkbewegungen notwendig, welche transiente Vorgänge hervorrufen. Es entsteht ein zeitlicher Versatz (Phase) zwischen dem Verlauf des Lenkradwinkels δ_H und der Querbeschleunigung $a_{y,dyn}$. Dies ist im Signalverlauf deutlich zu erkennen. Die Beurteilung der Modelle hinsichtlich der transienten Dynamik erfolgt anhand der qualitativen Bewertung der Phasentreue.

Um etwaige Einflüsse aus Fahrermodellen/-regelung auszuschließen, wird nur die Referenzsimulation im Closed-Loop simuliert. Für die Vergleichssimulationen mit den identifizierten Modellen werden derselbe Lenkradwinkel und dieselbe Geschwindigkeit als Eingänge benutzt. Der Verlauf der Querbeschleunigung der Referenzsimulation $a_{y,dyn,ref}$ sowie die Verläufe der simulierten Querbeschleunigungen der verschiedenen Modelle (ESM, KNN und bKNN) für die Datensätze (S70, S140) sind in Abbildung 6.12 dargestellt. Die Signalverläufe der 31 Modelle basierend auf den kleinsten Datensätzen (S5) sind in Abbildung 6.13 dargestellt und zeigen die Spreizung zwischen den einzelnen identifizierten Modell-/Parametersätzen. Zusätzlich sind für die KNN und bKNN die Verläufe der Querbeschleunigung mit zusätzlichem Rotationsanteil

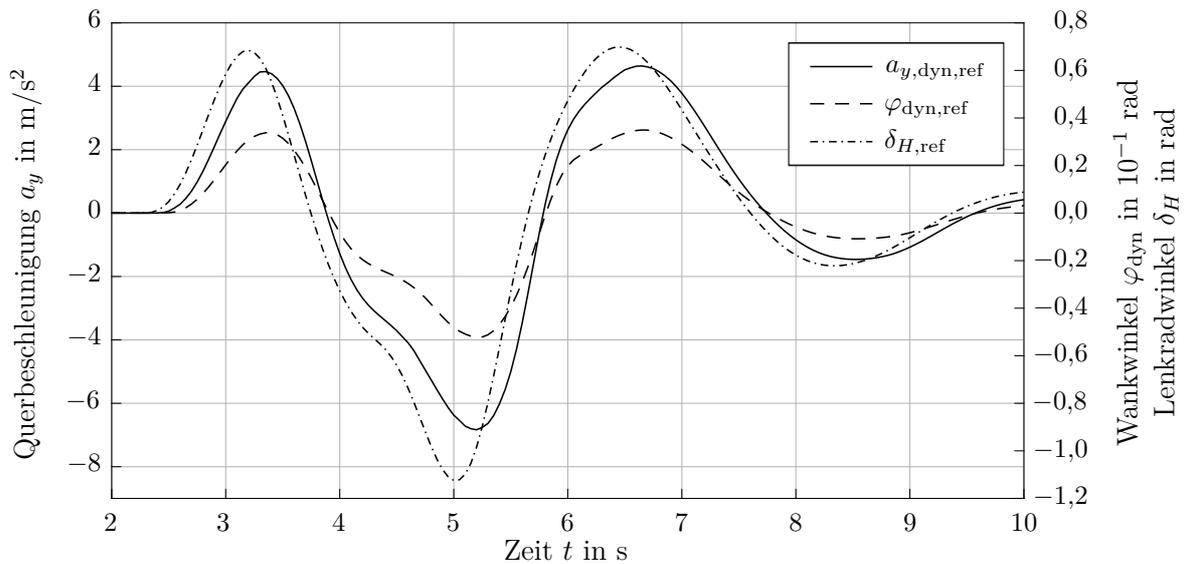
$$a_{y,rot} = \cos(\varphi_{dyn})a_{y,dyn} + \sin(\varphi_{dyn})g \quad (6.2)$$

ingezeichnet. Die Querbeschleunigung mit zusätzlichem Rotationsanteil $a_{y,rot}$ ist die Querbeschleunigung, wie sie in einem um den Wankwinkel φ_{dyn} rotierten Aufbau ohne

⁵⁰Bereitgestellt durch die Ford-Werke GmbH



(a) Aufbau der Parcourssegmente



(b) Signalverlauf des Referenzmodells für das Manöver Doppelter Spurwechsel

Abbildung 6.11: Fahrmanöver Doppelter Spurwechsel nach ISO 3888-1

Straßenquerneigung von einem Beschleunigungssensor gemessen würde (siehe Abschnitt 3.5). Diese wird als zusätzliche Referenz für KNN und bKNN eingezeichnet, da die experimentellen Modelle auf den gemessenen Querbeschleunigungswert $a_{y, \text{sen}}$ in einem rotierten Aufbau trainiert wurden.

Einspurmodell

Die Simulationsergebnisse der Einspurmodelle $a_{y, \text{ESM}, S70/S140}$ für die Datensätze S70 und S140 sind in Abbildung 6.12 dargestellt. Die Modellausgaben $a_{y, \text{ESM}, S70/S140}$ sind der Referenz $a_{y, \text{dyn}, \text{ref}}$ sehr ähnlich. Die Streuung zwischen den Modellen S70 und S140 ist minimal. Zwischen dem Einspurmodell und der Referenz bildet sich ein geringer Phasenversatz aus. Die Querbeschleunigung des Einspurmodells $a_{y, \text{ESM}}$ eilt der Referenzquerbeschleunigung voraus. Der Phasenversatz beträgt einen Rechenschritt und somit 0,1 s. Das maximale Residuum ist bei 5,6 s und ist $0,9 \text{ m/s}^2$ groß.

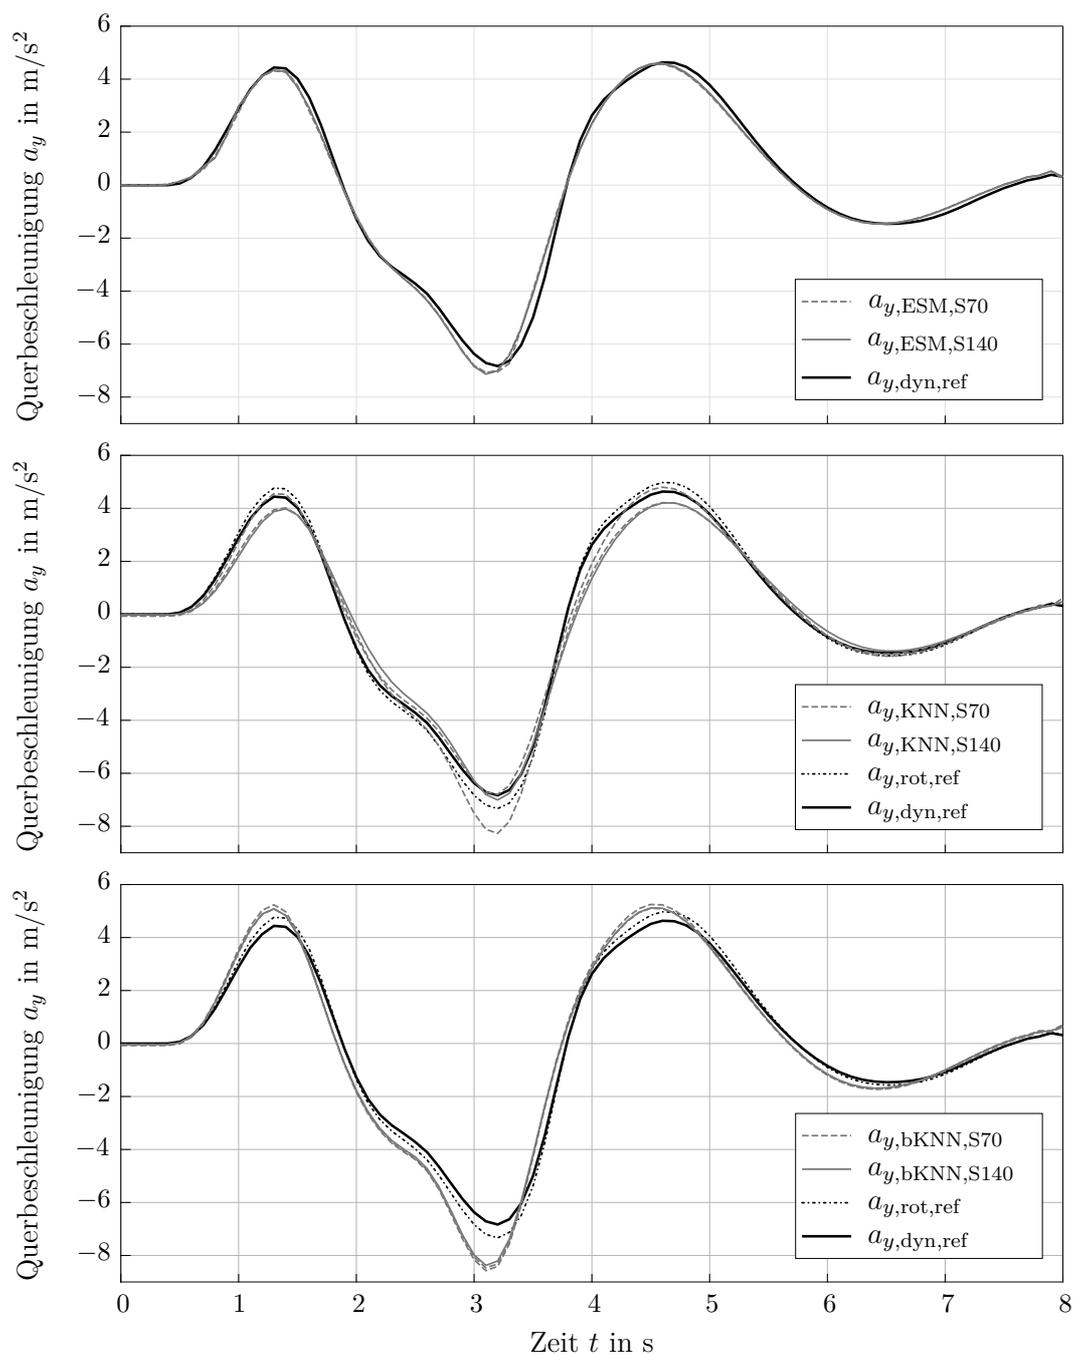


Abbildung 6.12: Vergleich einer Referenzsimulation eines Ford C-Max 2.0 l mit den identifizierten Modellen unterschiedlicher Datensätze (S70, S140) für einen doppelten Spurwechsel

Die Modelle der Datensätze S5 zeigen große Ähnlichkeit und eine geringe Streuung (siehe Abbildung 6.13). Das Einspurmodell bildet die Dynamik des transienten Verhaltens nicht vollständig ab, da die Fahrzustände des Manövers außerhalb der Modellgrenzen lie-

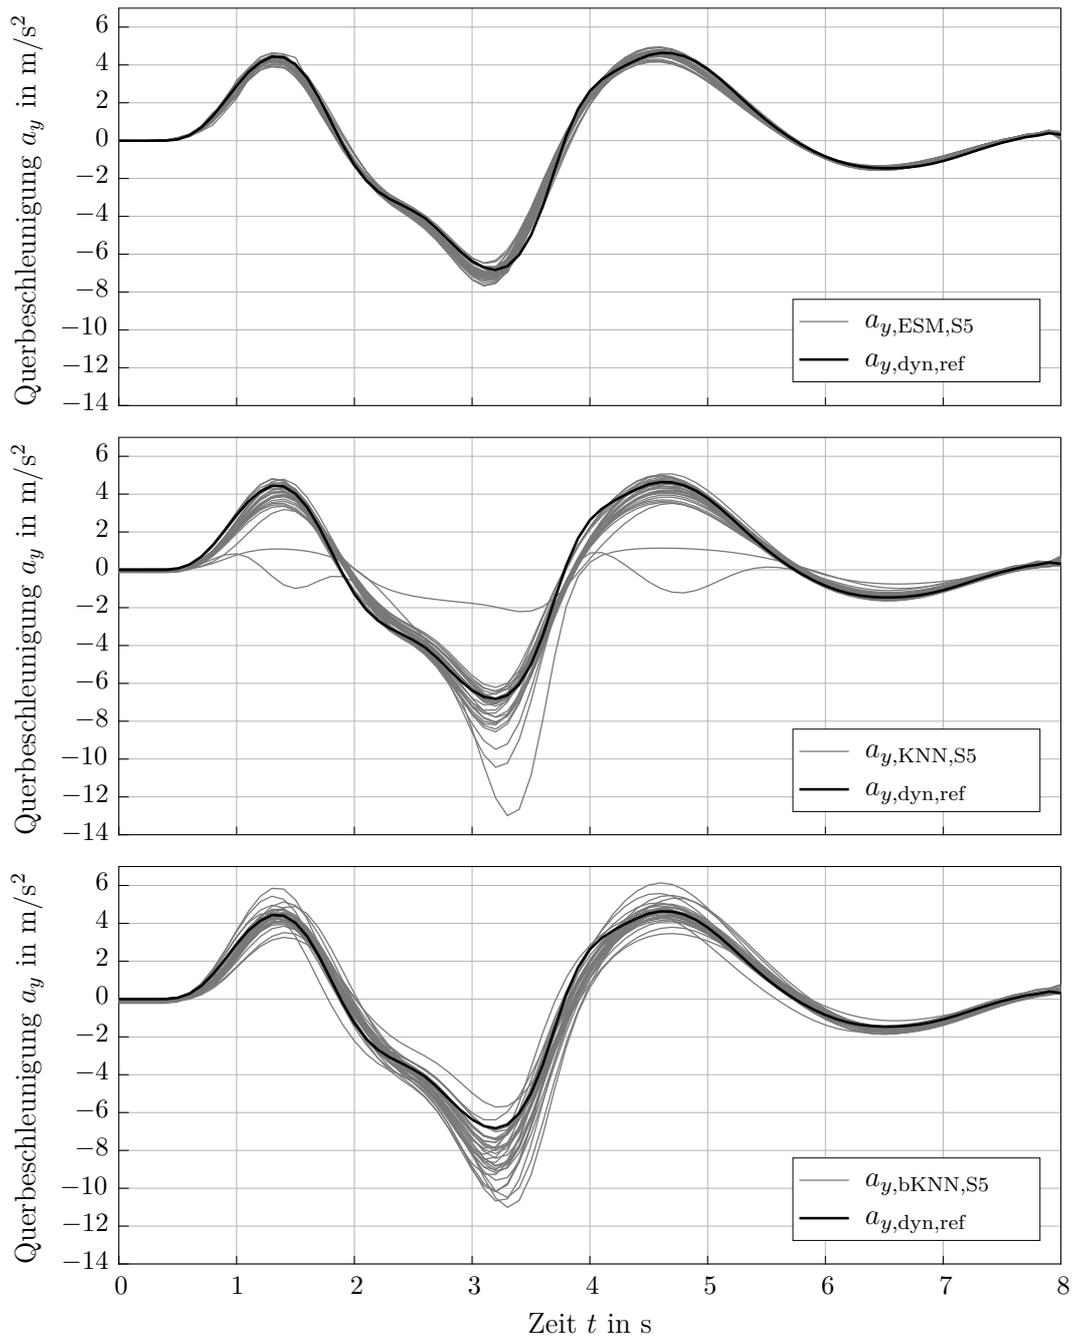


Abbildung 6.13: Vergleich einer Referenzsimulation eines Ford C-Max 2.0 l mit den identifizierten Modellen der Datensätze (S5) für einen doppelten Spurwechsel

gen. Abweichungen sind insbesondere durch die getroffenen Vereinfachungen – transiente Vorgänge im Reifen werden durch das Einspurmodell nicht vollständig beschrieben – zu begründen.

Künstliches Neuronales Netz

In Abbildung 6.12 ist der Querbeschleunigungsverlauf für die KNN basierend auf den Datensätzen S140, S70 dargestellt. Das Manöver Doppelter Spurwechsel wird durch die KNN (S70, S140) qualitativ korrekt abgebildet. Die KNN-Modelle basierend auf den Datensätzen S140, S70 sind phasentreu und bilden das transiente Verhalten gut ab.

In den vorherigen Analysen zu den KNN hat sich gezeigt, dass die Modellgenauigkeit stark vom Identifikationsdatensatz abhängt. Dieses Verhalten zeigt sich besonders stark für kleine Datensätze (S5). Das Modellverhalten der KNN für die Datensätze S5 ist in Abbildung 6.13 dargestellt. Die Streuung zwischen den Modellen ist sehr groß und einzelne Modelle innerhalb der Modellschar zeigen ein nicht physikalisch plausibles Modellverhalten. Die Mehrheit der Signalverläufe kann den Referenzverlauf allerdings qualitativ korrekt abbilden. Mit wachsender Datenmenge gleichen sich die Modelle in ihrem Verhalten an. Dennoch kann auch für die Modelle basierend auf den S70-Datensätzen eine Streuung beobachtet werden. Da die Streuung mit der Querbeschleunigung anwächst (siehe Stationäre Kreisfahrt, Abbildung 6.8), ist die Abweichung zwischen den Modellen zum Zeitpunkt maximaler Querbeschleunigung ($t \approx 3$ s) mit $1,5 \text{ m/s}^2$ maximal.

Weiter zeigen sich Unterschiede bei der Modellgenauigkeit zwischen Links- und Rechtskurven des Manövers. Für die beiden Linkskurven ($a_y > 0 \text{ m/s}^2$) wird die Referenzquerbeschleunigung unterschätzt. Für die einzelne Rechtskurve ($a_y < 0 \text{ m/s}^2$) wird der Referenzwert stark überschätzt.

Balanciertes Künstliches Neuronales Netz

Die Modelle der bKNN (sowohl die Modelle basierend auf S70 und S140 in Abbildung 6.12 als auch die Modelle basierend auf S5 in Abbildung 6.13) geben den Verlauf der Referenz qualitativ korrekt wieder. Die Streuung unter den Modellen S70, S140 ist sehr gering. Die Modellausgabe der bKNN (S70, S140) eilt der Querbeschleunigung der Referenz mit einem leichten Phasenversatz voraus. Für die S5-Modelle kann sowohl positiver als auch negativer Phasenversatz beobachtet werden. Die Querbeschleunigungswerte der bKNN ($a_{y,\text{bKNN},\text{S140}}$ und $a_{y,\text{bKNN},\text{S70}}$) sind größer als der Referenzwert $a_{y,\text{rot,ref}}$. Der Fehler zwischen Modell und Referenz ist mit 1 m/s^2 bei $t \approx 3$ s maximal (siehe Abbildung 6.12).

Die bKNN zeigen für alle Modelle physikalisch plausibles Verhalten. Die Modelle basierend auf einer großen Datenmenge (S70, S140) sind einander zusätzlich sehr ähnlich und weisen eine geringe Streuung auf.

Die Analyse zeigt, dass alle Modellierungsansätze aus 70 Std. oder 140 Std. Fahrdaten ein gutes Abbild der Referenz darstellen. Für die Datensätzen S5 in Abbildung 6.13 zeigen sich sehr deutlich die Unterschiede zwischen den Modellansätzen. Während die Schar der Einspurmodelle sehr ähnlich ist, ist die Streuung der KNN sehr groß. Auffällig ist, dass die bKNN für die Datensätze S5 besser sind als die KNN, obwohl deren Datensätze kleiner sind. Ganz offensichtlich wird durch die Balancierung das querdynamische Verhalten besser und schneller erlernt.

In Bezug auf den Phasenversatz gegenüber der Referenz zeigen die Einspurmodelle und bKNN für Datensätze S70 und S140 sehr ähnliches Verhalten. Die bKNN zeigen für die untersuchten Datensätze eine geringere Streuung als die KNN, sodass dieser Modellierungsansatz als robuster bewertet wird.

Der Referenzwert mit Rotationsanteilen $a_{y,rot,ref}$ wird sowohl durch die KNN als auch durch die bKNN deutlich überschätzt. Da die Unterschiede zwischen dem Versuchsträger und dem Simulationsmodell hinsichtlich Fahrzeuggewicht, Lage des Schwerpunkts, Alterung von Bauteilen, Reifen und Straßenbelag nicht exakt bekannt sind, und diese Auswirkungen auf die Referenzwerte haben, ist eine abschließende Bewertung der Modellgenauigkeit nur eingeschränkt möglich. Die Auswertung in Abschnitt 6.5.1 zeigt, dass der Sensorwert für weniger transiente, aber dennoch sehr dynamische Kurvenfahrten durch die bKNN sehr präzise vorhergesagt wird. Eine Validierung im realen Versuchsträger kann weitere Erkenntnisse bringen.

Grundsätzlich zeigen die experimentellen Ansätze, dass sie die Dynamik des Versuchsträgers erlernen können und dass ausreichend Informationen im Datensatz enthalten sind. Eine sinnvolle Datenauswahl ist entscheidend. Wie diese aussehen kann, ist eine nicht triviale Aufgabe. Die Balancierung der Daten und die damit gezielte Datenauswahl zeigt, welchen Einfluss die Datenauswahl auf die identifizierten Modelle hat, zudem kann die Modellgüte dadurch deutlich verbessert werden.

6.6 Erkenntnisse der Modellvalidierung

Die Validierung der Modelle wird an verschiedenen subjektiven und objektiven Kriterien durchgeführt. Die Validitätsanforderungen aus Abschnitt 6.1 können zu großen Teilen für die verschiedenen Modellierungsansätze (theoretisch und experimentell) erfüllt werden und reichen teilweise deutlich über den geforderten und erwartbaren alltäglichen Betriebsbereich von Pkw hinaus. Die Validität der Modelle hängt maßgeblich mit dem Datenumfang, der für die Identifikation genutzt wird, zusammen. NDS können zukünftig einen Beitrag zur Identifikation der Fahrzeugdynamik leisten.

Vergleich der Modellierungsansätze

Es konnte der Nachweis erbracht werden, dass der durch NDS erzeugte Datensatz zur Identifikation genutzt werden kann.

- Mithilfe der theoretischen Modellbildung kann ein Parametersatz gefunden werden, der das dynamische Verhalten des Versuchsträgers beschreibt.
- Die Dynamik des Versuchsträgers lässt sich mit experimentellen Modellen valide abbilden. Für Anwendungen, in denen es nicht möglich ist, ein schlüssiges theoretisches Modell zu erstellen, können naturalistische Fahrdaten, die im Betrieb ohnehin anfallen, für die Erzeugung valider Modelle genutzt werden.

Am Prozessende der Systemanalyse aus Abbildung 2.1 steht der Vergleich aus theoretischem und experimentellem Modell. Die Validierung zeigt, dass mit verschiedenen Modellierungsansätzen sehr ähnliches Modellverhalten beobachtet werden kann. Bezogen auf die Validierungsvorgaben konnte an unabhängigen Daten gezeigt werden, dass das querdynamische Verhalten gut erlernt wird und der Fehler in der Größenordnung der Störgröße liegt. Für einzelnen Fahrsituationen werden die Validierungsziele nicht erreicht. Eine Verbesserung der Modellgenauigkeit ist nur durch die Reduzierung der Störgrößen zu erwarten. Positiv ist hierbei hervorzuheben, dass die identifizierten Modelle auch eine hohe Güte für Betriebszustände zeigen, die während der Fahrstudie sehr selten beobachtet wurden. Der Anwendungsbereich der Modelle ist somit nicht ausschließlich auf alltägliche Manöver beschränkt.

Ein wesentlicher Unterschied zwischen theoretischem und experimentellem Modell liegt in der Anzahl der Modellfreiheitsgrade. Das theoretische Modell kann aufgrund der vorgegebenen Modellstruktur die Wankbewegung des Fahrzeugaufbaus nicht abbilden, sodass für hochdynamische Fahrereignisse (bspw. Autobahnauffahrt) Abweichungen im Modellverhalten zwischen experimentellem und theoretischem Modell beobachtet werden können. Eine Erweiterung des Linearen Einspurmodells (theoretisches Modell) zu einem nichtlinearen Einspurmodell mit Wankmodell (siehe Tabelle 2.1) ist daher denkbar. Dies würde die Anzahl der Freiheitsgrade auf bis zu sieben erhöhen und den Einsatzbereich des Modells deutlich erweitern. Der Datenbedarf bei der Modellierung mit experimentellen Modellen ist verglichen mit theoretischen Modellen größer. Eine rein auf experimentellen Daten basierende Modellbildung sollte auf einer Datenbasis mit mehr als 20 Std. Fahrdaten fußen, sodass ausreichend Informationen gesammelt werden können.

Der Prozess der Systemanalyse aus Abbildung 2.1 ist iterativ aufgebaut. Mit dem gewonnenen Wissen über das Systemverhalten, das Modellverhalten und die Störgrößen kann der Prozess mit dem Ziel der Steigerung der Modellgüte erneut durchlaufen werden. Ein solches Vorgehen ist allerdings zeitlich sehr aufwendig und nur sinnvoll, wenn weitere Messwerte verfügbar gemacht werden.

Einfluss der Datenbasis auf die Modellgenauigkeit

Eine geringe Versuchskontrolle während einer NDS macht eine umfassende Datenanalyse zu einem zentralen Element des Identifikationsprozesses.

- **Datenmenge**

Die Analyse der Modelle zeigt, dass für eine ausreichend große Fahrstudie der Informationszugewinn abnimmt und sich somit auch die identifizierten Modelle angleichen. Die Studie sollte bei Erreichen einer adäquaten Datenmenge beendet werden. Für naturalistische Fahrten mit dem Ziel der Identifikation der Querdynamik wird eine adäquate Datenmenge zwischen 20 Std. und 70 Std. Fahrdauer erreicht. Für Modelle aus 20 Std. Fahrdaten kann bereits eine hohe Modellrobustheit erzielt werden. In Kombination mit umfassendem Modellwissen (ESM) können 20 Std. Fahrdaten für die Identifikation bereits ausreichen. Mit 70 Std. Fahrdaten wird Adäquanz für

die Identifikationsanforderungen dieser Arbeit erreicht. Weitere Daten führen zu keiner oder sehr geringer Steigerung des Informationsinhalts und somit nur zu einer geringen Verbesserung der Modellgenauigkeit.

- **Datengewichtung**

Die Analysen der Fahrdaten zeigen, dass die Verteilung innerhalb der Menge der aufgezeichneten Messgrößen nicht homogen ist und manche Merkmale häufiger auftreten als andere. Insbesondere hochdynamische und transiente Fahrmanöver sind sehr selten und können daher nicht häufig beobachtet werden.

Das Identifikationsergebnis der experimentellen Modelle kann durch eine Balancierung der Daten maßgeblich beeinflusst und verbessert werden. Die Untersuchungen belegen das Potential einer Balancierung besonders für seltene Fahrereignisse. Im Falle der vorliegenden Arbeit können durch eine Segmentierung der Fahrten und anschließender Neugewichtung der Messgrößenverteilung die Modellgenauigkeit sowie die Modellrobustheit für die experimentellen Modelle gesteigert werden.

Limitierungen von NDS für Identifikationszwecke

Das gewählte Studiendesign besitzt für das Identifikationsvorhaben Limitierungen, die für eine erfolgreiche Anwendung beachtet werden müssen:

- **Fehlende Versuchskontrolle**

In NDS kann das System (hier der Versuchsträger) nicht gezielt angeregt werden, was wiederum die Identifikation erschwert. Das Studiendesign schließt keine Manöver oder Situationen aus – sämtliche physikalisch möglichen Zustände können beobachtet werden –, allerdings ist die Wahrscheinlichkeit, hochdynamische Ereignisse in alltäglichen Fahrten zu beobachten, sehr gering. Die Methode der NDS scheint für die gezielte Identifikation hochdynamischer Ereignisse nicht optimal zu sein (insbesondere, wenn diese in Kombination mit bestimmten Umwelteinflüssen untersucht werden sollen, z. B. hohe Querschleunigungen bei geschlossener Schneedecke). Bekannte Standardmanöver sind hier die bessere Wahl, da sie eine explizite und gezielte Anregung dieser Bedingungen ermöglichen.

- **Sensorik**

Das gewählte Studiendesign nutzt ausschließlich die verfügbaren Signale fahrzeugeigener Sensoren, ohne hierbei auf proprietäres Wissen von Fahrzeugherstellern zurückzugreifen. Bei der Identifikation können folglich nur Signale genutzt werden, die bei der Messwerterfassung verfügbar sind. Für diese Studie ist die Modellgenauigkeit aufgrund der fehlenden Erfassungsmöglichkeiten der Aufbaurotation limitiert. Ansätze zur Schätzung der Straßenquerneigung und des Fahrzeugwankwinkels finden sich in DING, MASSEL (2005), HAHN et al. (2004), REHM (2010) oder TSENG (2001) und machen weiteres Modellwissen und Parameterwissen (bspw. Trägheitsmoment um die Wankachse, Wankpolhöhe, Feder-/Dämpfercharakteristiken) sowie weitere Messsignale (etwa Gierrate oder Differential-GPS) notwendig.

Zusammenfassung und weiterführende Aspekte

Die vorliegende Arbeit hat das Potential der Daten aus naturalistischen Fahrstudien (NDS) für die Modellbildung der Fahrzeugdynamik untersucht. Dabei werden unterschiedliche Aspekte hinsichtlich des Identifikationsprozesses, der gewonnenen Informationen sowie der erreichbaren Modellgüte betrachtet. Im Folgenden werden die wesentlichen Ergebnisse und Kernpunkte zusammengefasst, zudem werden Anknüpfungspunkte für weitere Themenfelder genannt.

7.1 Zusammenfassung und Beitrag dieser Arbeit

Anhand einer NDS, die über den Zeitraum von einem Jahr Fahrdaten alltäglicher Fahrten gesammelt hat, wird gezeigt, welches Potential ein solches Vorgehen hinsichtlich der Fahrdynamikmodellierung birgt. Die erfolgreiche Durchführung einer NDS bedarf der Abänderung des klassischen Identifikationsprozesses, um der sehr langen Dauer und dem explorativen Charakter einer solchen Studie gerecht zu werden. Wird dies berücksichtigt, kann auf der Basis der im Pkw vorhandenen Sensoren eine Datenbasis aufgezeichnet werden, die es erlaubt, Fahrdynamikmodelle zu parametrieren oder sogar experimentelle Modelle zu trainieren.

Kapitel 3 beschreibt, welche Anpassungen im Identifikationsprozess vorgenommen werden müssen, um eine Studie zur Identifikation fahrdynamischer Zusammenhänge zu ermöglichen. Dies ist insbesondere im Vergleich zu den erprobten und üblicherweise verwendeten standardisierten Fahrversuchen ein wichtiger Aspekt.

Ausgehend von physikalischen Grenzen eines Pkws, der erwartbaren Betriebsbedingungen und statistischer Größen wird gezeigt, wie der Informationszugewinn über die Dauer einer solchen Studie abnimmt. Das Verständnis hierzu ist entscheidend, da nicht im Vorfeld eine

notwendige Studiendauer festgelegt werden kann. Dies ist ein deutlicher Unterschied zu den klassischen Methoden. Die Erörterungen zur Adäquanz der Daten, d. h., der Wahrscheinlichkeit mit weiteren Messungen weitere Informationen zu gewinnen (vgl. Kapitel 3 und 4), stellt einen entscheidenden Punkt für die Nutzung von NDS für die Fahrdynamikidentifikation dar. Der hybride Ansatz aus statistischen Bewertungsmaßstäben sowie einer Bewertbarkeit anhand physikalischer Größen ist ein leistungsstarkes Instrument, um die Adäquanz der Daten zu beurteilen und damit eine Studie passend zu beenden.

Anhand von verschiedenen Modellen kann außerdem gezeigt werden, dass die Informationslage in Daten aus einer NDS ausreichend ist, um valide Modelle für weite Teile der Fahrzeugdynamik zu erzeugen. Hierfür wird in Kapitel 5 und 6 die Querdynamik eines Pkws auf der Basis theoretischer und experimenteller Modelle untersucht und anhand einer zuvor validierten Referenz bewertbar gemacht. Dieselben Analysen zeigen auch deutlich, welche Grenzen das beschriebene Vorgehen hat. Der Einfluss der Datenmenge und somit der Dauer einer NDS auf die erreichbare Modellgenauigkeit wird untersucht, und es kann gezeigt werden, dass sich der Informationsinhalt großer Datensätze und dadurch auch die identifizierten Modelle selbst zunehmend angleichen.

In Summe schließt die Arbeit damit eine Lücke zwischen den Themenfeldern NDS und der Fahrdynamikmodellierung, indem nachgewiesen wurde, dass Daten aus NDS zur gezielten Fahrdynamikmodellierung eingesetzt werden können.

7.2 Anknüpfungspunkte zukünftiger Arbeiten

Diese erste Verwendung einer langfristig angelegten NDS im Themengebiet Fahrzeugdynamikmodellierung skizziert vielfältige Potentiale, die für aktuelle und zukünftige Forschungsthemen oder die direkte Nutzung im automobilen Umfeld interessant sind.

Der Nachweis einer Nutzbarkeit von naturalistischen Felddaten zur Beschreibung der Fahrzeugdynamik führt zu verschiedenen Möglichkeiten. Fahrdynamikmodelle können ohne spezielle Tests auf dafür vorgesehenen Teststrecken erstellt oder parametrisiert werden. Lediglich hochdynamische Szenarien könnten hierbei unzureichend abgebildet werden, da Normalfahrten im Rahmen einer NDS diese Dynamikbereiche nicht abdecken. Interessant ist dies vor allem für Nicht-OEM-Organisationen, die dennoch gezielt Fahrzeugmodelle aufbauen wollen.

Für OEMs sind die Erkenntnisse ebenfalls spannend. So kann z. B. bereits nach wenigen Stunden ein individuell für ein Fahrzeug angepasstes Dynamikmodell erstellt werden, welches z. B. für verschiedene Systeme eingesetzt werden kann. Dieselben Modelle könnten auch zur Detektion von Veränderungen, die im Laufe der Betriebsdauer entstehen, genutzt werden und so unter anderem frühzeitig auf Verschleiß hindeuten. Dies ist ein wichtiger Aspekt bei Überlegungen zur Predictive Maintenance oder zur Überwachung eines Flottenzustandes.

Die verwendeten Methoden zur Informationsbewertung mit direktem Bezug zur jeweiligen Dynamikkenngroße sind ebenfalls wertvoll, wenn Datengrundlagen für das Training

experimenteller Modelle geschaffen werden sollen. Die gezielte Kombination von hochdynamischen Manövern (z. B. aus Standardtests) mit Normalfahrten kann dazu genutzt werden, den gesamten Dynamikbereich ideal abzudecken. Eine Bewertung der verfügbaren Information kann dafür sorgen, dass keiner der Teilbereiche überrepräsentiert ist. Ebenso ist aus Effizienzgründen darauf zu achten, dass nicht unnötig viele Daten verwendet werden.

Weiterführende Betrachtungen und Ergänzungen

A.1 Messgrößenerfassung

A.1.1 Loggerkomponenten

Für die Fahrdatenaufzeichnung wird ein Datenlogger entwickelt und aufgebaut. Die Komponenten des Datenloggers sowie die Preise zum Einkaufszeitpunkt im ersten Quartal 2019 sind in Tabelle A.1 aufgelistet.

Tabelle A.1: Komponenten des Datenloggers

Komponente	Bezeichnung	Kosten
Einplatinencomputer	Raspberry 3 B+	32 €
UPS-Board	Strom Pi 3	40 €
UPS-Batterie	Strom Pi 3 Battery Pack	25 €
CAN-Board	PiCAN 2	40 €
Speicherkarte	MicroSD 32 GB	8 €
Portables Speichermedium	USB-Stick 128 GB	25 €
Weitere Teile		45 €
Summe		215 €

A.1.2 CAN-Messgrößen

Eine Übersicht über alle Messgrößen der Fahrstudie wird in Tabelle A.2 gegeben. In dieser Tabelle sind die Messgrößen in verschiedene funktionale Gruppen eingeteilt. Neben der Beschreibung jeder Messgröße werden dessen Formelzeichen, Einheit sowie die mittlere Kommunikationsfrequenz angegeben.

Tabelle A.2: Aufgezeichnete Fahrdynamikmessgrößen im Versuchsträger. Die mittlere Kommunikationsfrequenz der jeweiligen Messgröße über die gesamte Studiendauer wird mit \bar{f} bezeichnet.

	Symbol	Einheit	\bar{f}	Beschreibung
Fahrer	δ_H	rad	6,8 Hz	Lenkradwinkel
	T_L	Nm	4,1 Hz	Lenkmoment
	p_a	%	4,8 Hz	Gaspedalstellung
	p_b	%	6,8 Hz	Bremspedalstellung
Starrkörperbewegung	v_x	m/s	6,8 Hz	Longitudinale Geschwindigkeit
	a_x	m/s ²	6,8 Hz	Longitudinale Beschleunigung
	a_y	m/s ²	6,8 Hz	Laterale Beschleunigung
	$\dot{\psi}$	rad/s	6,8 Hz	Gierrate (<i>nicht über den gesamten Studienzeitraum verfügbar</i>)
Antrieb	$\omega_{vl, vr}$	m/s	2,8 Hz	Raddrehzahl vorne links/rechts
	$p_{vl, vr}$	kPa	6,8 Hz	Bremsdruck vorne links/rechts
Verbr.-motor	ω_{VM}	rad/s	2,8 Hz	Drehzahl des Verbrennungsmotors
	T_{PG}	Nm	2,8 Hz	Antriebsmoment am Ausgang des Planetengetriebes
Elektromotor	ω_{EM}	rad/s	2,8 Hz	Drehzahl des Elektromotors
	T_{EM}	Nm	2,8 Hz	Antriebsmoment am Ausgang des Elektromotors
Batterie	I_{Bat}	A	0,5 Hz	Batteriestrom
	U_{Bat}	V	0,5 Hz	Batteriespannung
	$E_{Bat, est}$	kWh	0,5 Hz	Verbleibender Energieinhalt bis zur Entladung
	$P_{In, max}$	kW	0,5 Hz	Maximale Ladeleistung
	$P_{Out, max}$	kW	0,5 Hz	Maximale Enladelleistung
	SOC	-	0,5 Hz	Ladezustand

A.2 Installation einer GPS-Antenne in den Versuchsträger

In Abschnitt 3.3 wird beschrieben, dass der Versuchsträger nachträglich mit einer GPS-Antenne ausgestattet wurde. Für die Analyse in Abschnitt 4.1.1 wird die Annahme getroffen, dass die Verteilung der nicht klassifizierten Daten (bezogen auf die Straßentypnutzung) der Verteilung der klassifizierten Daten folgt. Ein Vergleich der Geschwindigkeiten

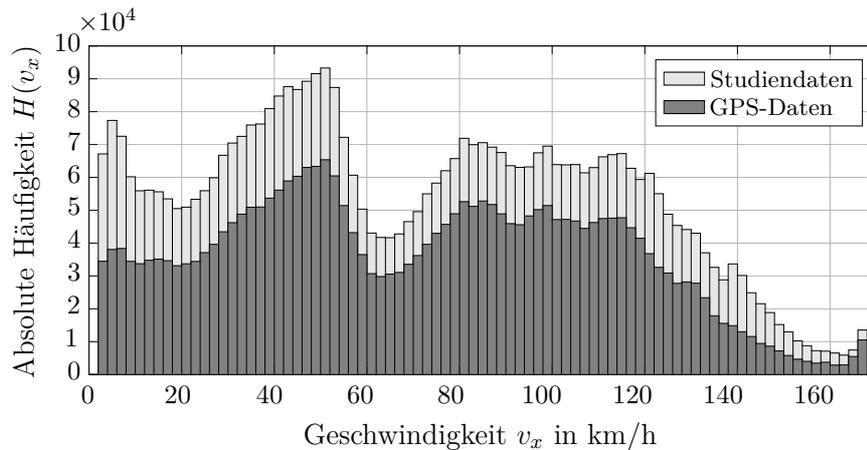


Abbildung A.1: Geschwindigkeitsverteilung der Studiendaten gegenüber den GPS-Daten

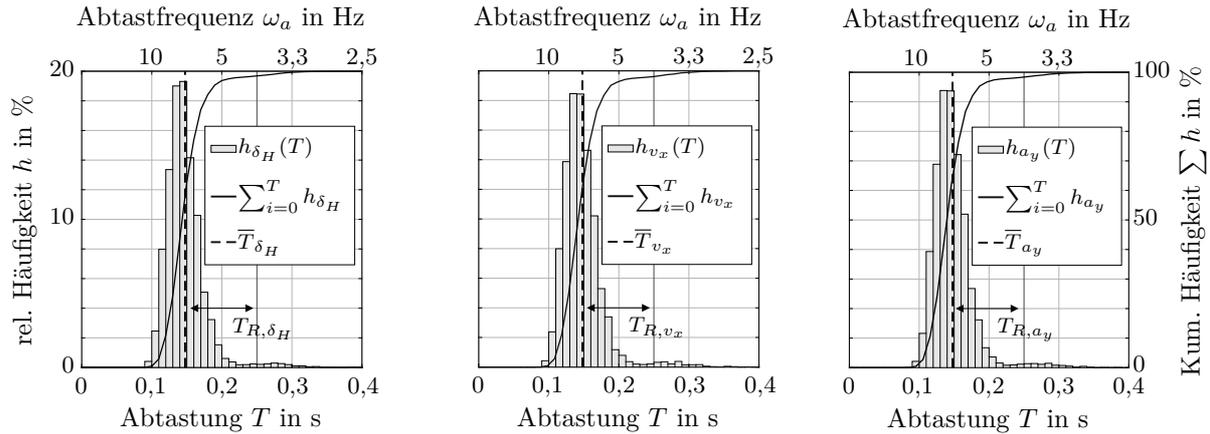
aller Studiendaten (CAN-Messung) und der Geschwindigkeiten aus GPS-Messungen ist in Abbildung A.1 dargestellt. Die Häufigkeitsverteilungen der Geschwindigkeiten beider Datenmengen ähneln sich sehr. Da die Ausprägung der einzelnen Geschwindigkeitsmoden stark von der Straßentypnutzung abhängt (siehe Analyse in Abschnitt 4.2.1) und eben diese für beide Datenmengen sehr ähnlich sind, wird gefolgert, dass die Verteilung der nicht klassifizierten Daten der Verteilung der klassifizierten Daten in guter Näherung folgt.

A.3 Signalverarbeitung

In Abschnitt 2.4 werden die wesentlichen Schritte zur Signalverarbeitung präsentiert. Einige Ergänzungen folgen in diesem Abschnitt.

A.3.1 Kommunikation mit dem Fahrzeug-Gateway

Die Kommunikationsrate zwischen Datenlogger und dem Diagnose-Gateway des Versuchsträgers besitzt zwei Eigenschaften, die die weiteren Identifikationsschritte erschweren. Zum einen ist die Kommunikationsrate nach oben limitiert und zum anderen ist diese nicht äquidistant. Die Verarbeitung von nicht äquidistanten Signalen wird in Abschnitt 3.4 beschrieben. Die Kommunikationsrate mit dem Gateway ist insofern wichtig, da diese die maximal messbare Frequenz (siehe Abtasttheorem in Abschnitt 2.4.1) festlegt. Experimente am Versuchsträger zeigen, dass das Gateway zwischen 60 bis 80 Anfragen pro Sekunde (u. a. abhängig von der Messgrößenwahl) beantworten kann. Die Verteilung der Abtastintervalle für die Messgrößen v_x , δ_H und a_y sind in Abbildung A.2 dargestellt. Es wird die relative Häufigkeit der Intervalle $h(T)$ als Histogramm dargestellt, in denen die CAN-Nachrichten für die einzelnen Messgrößen empfangen werden. Die kumulierte



(a) Zeitintervalle zwischen Datenpunkten des Lenkwinkels δ_H (b) Zeitintervalle zwischen Datenpunkten der Längsgeschwindigkeit v_x (c) Zeitintervalle zwischen Datenpunkten der Querbeschleunigung a_y

Abbildung A.2: Abtastraten verschiedener Messgrößen während der Fahrstudie: Relative Häufigkeitsverteilung $h(T)$ und kumulierte relative Häufigkeit $\sum_{i=0}^T h(T)$ der Intervalllängen aufeinanderfolgend empfangener Diagnosenachrichten am Datenlogger für die Messgrößen δ_H, v_x, a_y über die Studienlaufzeit. Das durchschnittliche Abtastintervall \bar{T} für das jeweilige Messsignal ist als gestrichelte Linie eingezeichnet.

relative Häufigkeit $\sum_{i=0}^T h(T)$ der Abtastraten ist mit einer durchgezogenen Linie dargestellt. Das durchschnittliche Abtastintervall über den gesamten Studienzeitraum ist als gestrichelte Linie eingezeichnet. Für die Einhaltung des Abtasttheorems wird eine Abtastrate von mindestens 4 Hz gefordert (siehe Abschnitt 3.3.2). Die maximal erlaubte Intervalllänge ist folglich $T_g = \frac{1}{4\text{Hz}} = 0,25\text{ s}$. Für ungleichförmig abgetastete Signale gilt das Abtasttheorem als erfüllt, wenn $\bar{\omega}_a \geq 2\omega_g$ ist. Die durchschnittliche Abtastrate der Messsignale ist $\bar{\omega}_a = 6,8\text{ Hz}$. Das Abtasttheorem wird erfüllt. Die Abtastreserve, bis zu welcher die durchschnittliche Abtastrate absacken darf, bevor das Abtasttheorem verletzt wird, ist mit T_R dargestellt.

A.3.2 Signalrekonstruktion

Die Abtastrate ist eine wichtige Kenngröße, die bei der Erfassung kontinuierlicher Signalverläufe einer Messgröße (bspw. Fahrzeuggeschwindigkeit v_x) zu beachten ist. Das Ziel der Messung ist es, dass der Signalverlauf der Messgröße durch einzelne Messstellen (entsprechend der Abtastung) vollständig erfasst wird. In Abschnitt 2.4.1 wird beschrieben, wie die minimale Abtastrate basierend auf dem Abtasttheorem festgelegt wird. Die Einhaltung des Abtasttheorems ist eine notwendige Bedingung, um den kontinuierlichen Signalverlauf aus den abgetasteten Messstellen vollständig rekonstruieren zu können. Gleichzeitig garantiert die Einhaltung des Abtasttheorems nicht zwangsläufig, dass die Rekonstruktion des kontinuierlichen Signals fehlerfrei gelingt. Abweichungen zwischen originalem Signal und rekonstruiertem Signal können die Folge sein.

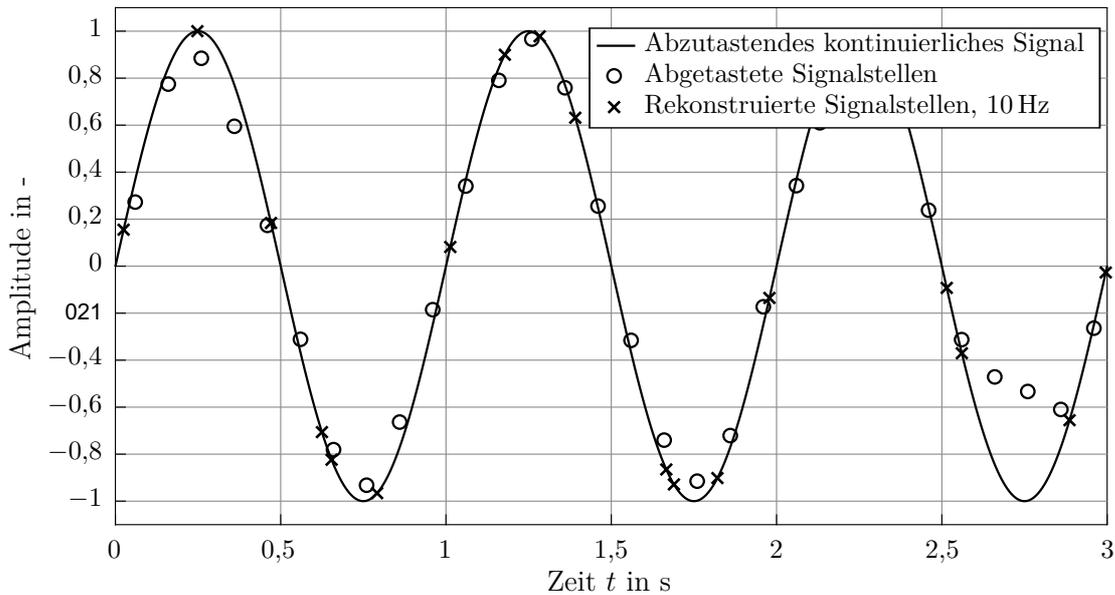


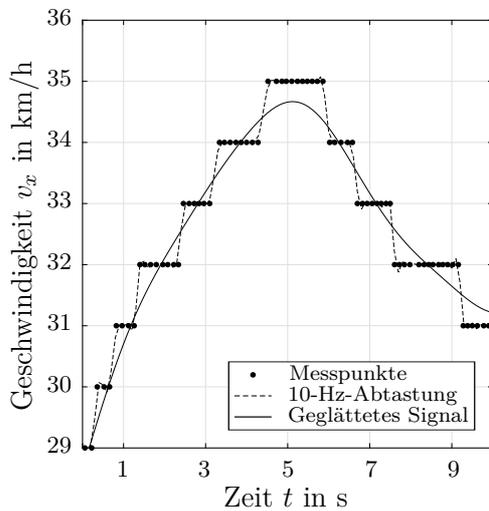
Abbildung A.3: Maximaler Fehler, der bei der Abtastumsetzung und Linearisierung entstehen kann

In Abschnitt 3.4 wird die Signalabtastung und -verarbeitung beschrieben. Die Abtastung erfolgt nicht äquidistant. Die Messwerte werden auf ein äquidistantes Abtastgitter mit 10 Hz umgesetzt (Vorgehen wird in Abschnitt 3.4 beschrieben). Die Eigenschaften des zu messenden Signals sind weitgehend unbekannt. Es wird davon ausgegangen, dass die maximale Signalfrequenz bei 2 Hz liegt (vgl. Beschreibung in Abschnitt 3.3.2). Der maximale Fehler bei der Abtastumsetzung entsteht bei hohen Signalfrequenzen und gleichzeitig großen Abtastintervallen. Die Abtastrate kann aufgrund technischer Limitierungen nicht auf die Dynamik des Messsignals angepasst werden und die Abtastzeitpunkte unterliegen einer zufälligen Streuung. Zur Fehlerabschätzung wird die gewählte Abtastumsetzung anhand eines Beispiels untersucht. In Abbildung A.3 ist eine Sinusschwingung mit 2 Hz, die maximal erwartete Signalfrequenz, dargestellt. Das Signal wird nicht äquidistant abgetastet. Die Abtastzeitpunkte sind in Abbildung A.3 mit Kreuzen dargestellt. Die durchschnittliche Abtastrate entspricht 6,8 Hz (vgl. Anhang A.3.1). Die Variation der Abtastintervalle ist zufällig gewählt. Das auf 10 Hz umgesetzte Signal (Signalverarbeitung wie in Abschnitt 3.4 beschrieben) ist mit Kreisen eingezeichnet. Der Fehler, der bei der Abtastumsetzung entsteht, ist der Abstand zwischen dem abzutastenden Signal (durchgezogene Linie) und dem umgesetzten Signalpunkten (Kreisen). Dieser ist an den Maxima der Schwingung maximal. Der typische Fehler liegt hierbei bei etwa 5 % bis 10 %. Für das Abtastintervalle von $T = 0,4$ s zum Zeitpunkt $t = 2,5$ s liegt der Fehler in der Größenordnung von 40 %. Ein Fehler dieser Größenordnung verfälscht die Messung deutlich. Es kann allerdings einschränkend festgehalten werden, dass Abtastintervalle von 0,4 s sehr selten sind (siehe Abbildung A.2) und ein Fehler dieser Größe nur in Kombination mit der maximalen Signaldynamik auftreten kann. Daher wird die Eintrittswahrscheinlichkeit

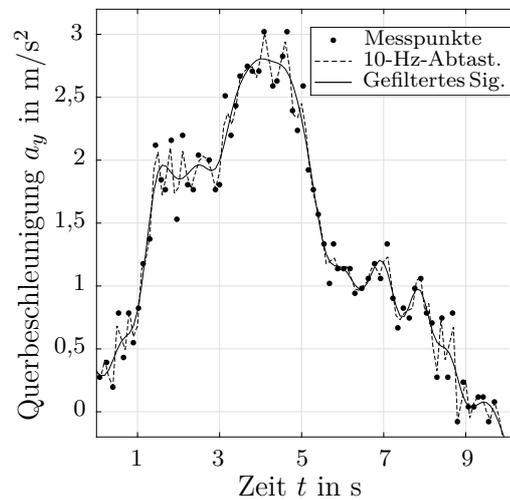
als ausreichend selten bewertet, sodass dieser Fehler in Anbetracht der umfangreichen Datenbasis vernachlässigbar ist. Für die durchschnittliche Abtastrate von 6,8 Hz ist bei einer Signalfrequenz von 2 Hz mit einem maximalen Fehler von 10 % zu rechnen. Dieser lässt sich mit der gewählten Methode nicht vermeiden. Für alltägliche Fahrten wird der Fahrzeugaufbau nur in den wenigsten Fahrscenarien mit der maximalen Frequenz von 2 Hz schwingen. Für die allermeisten Fahrsituationen wird die Systemfrequenz deutlich unterhalb der maximalen Frequenz liegen. Somit kann ein maximaler Fehler von 10 % aufgrund der seltenen Eintrittswahrscheinlichkeit akzeptiert werden.

A.3.3 Signalaufbereitung

Digitale Messwerte liegen in diskreten Stufen vor. Für die Fahrzeuggeschwindigkeit wird der physikalische Messwert in Stufen vor 1 km/h dargestellt. In Abbildung A.4a ist der Geschwindigkeitsverlauf für einen Fahrabschnitt dargestellt. In der Abbildung sind die vom Gateway stammenden Messwerte als Punkte sowie das auf 10 Hz umgeformte Signal als gestrichelte Linie dargestellt. Ohne weitere Aufbereitung liegt die Geschwindigkeit als ein stufenartiges Signal mit Sprüngen an den Übergängen zwischen zwei Stufen vor. Aus dem Systemverständnis zur Bewegung von Festkörpern ist bekannt, dass deren Geschwindigkeitsverlauf wertkontinuierlich ist und sprungartige Geschwindigkeitsänderungen eine unendliche hohe Beschleunigung voraussetzen, die wiederum aufgrund der Masse des Kör-



(a) Signalaufbereitung der Fahrzeuggeschwindigkeit: Abtastumsetzung und Glättung



(b) Signalaufbereitung der Querbeschleunigung: Abtastumsetzung und Tiefpassfilterung

Abbildung A.4: Die Signalverarbeitung erfolgt in drei Stufen und ist exemplarisch für die Messgrößen v_x und a_y dargestellt. Das physikalische Rohsignal wird zu einem mit 10 Hz abgetasteten Signal (gestrichelte Linie) verarbeitet. Im Anschluss werden die Signale anwendungs- und signalspezifisch aufbereitet. Die Fahrzeuggeschwindigkeit wird mittels Kerndichtenschätzers geglättet und die Querbeschleunigung mittels Tiefpassfilter gefiltert.

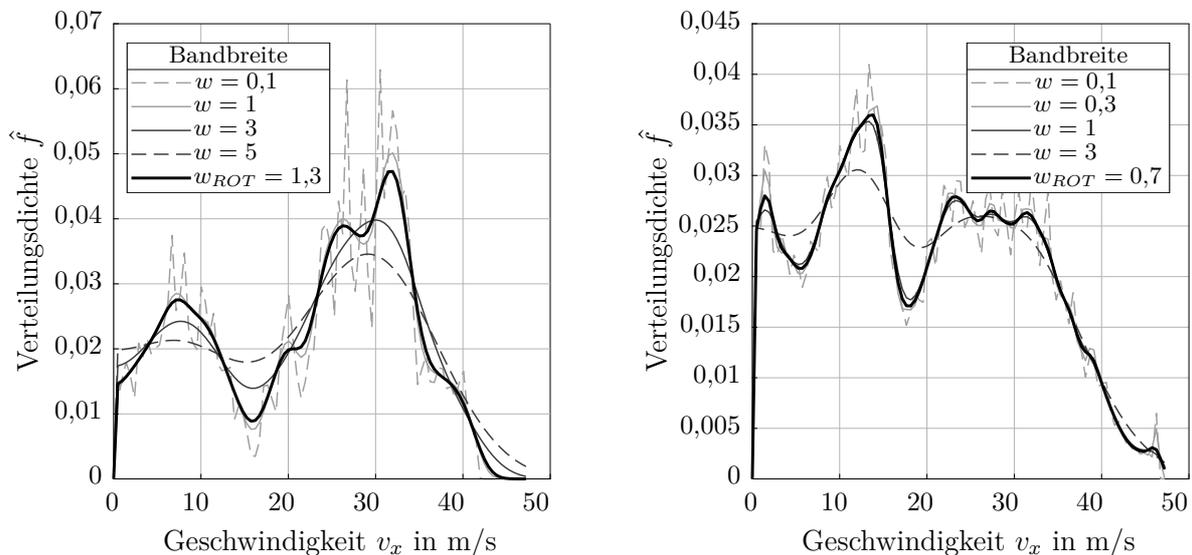
pers nicht möglich ist. Es ist plausibel anzunehmen, dass sich die Geschwindigkeit langsam und nicht sprunghaft ändert. Mit diesem Wissen wird ein Glättungsfilter eingesetzt. Der verwendete Glättungsfilter basiert auf einem Kerndichteschätzer (siehe Abschnitt 2.5.2) und wird für einen ähnlichen Anwendungsfall in JUN et al. (2006) präsentiert. Das resultierende Signal ist als durchgezogene Linie dargestellt. Für die weiteren Signale sind die Diskretisierungsstufen ($0,1^\circ$ für δ_H bzw. $0,01 \text{ m/s}^2$ für $a_{x,y}$) deutlich kleiner, sodass ein Glättungsfilter für diese Signale nicht notwendig ist.

Für die Signalaufbereitung der Querbeschleunigung wird ein Tiefpassfilter verwendet. In Abbildung A.4b sind die einzelnen Messpunkte sowie das auf 10 Hz umgeformte Signal dargestellt. Das Signal schwingt stark, sodass ein Tiefpassfilter das Signal in der maximalen Frequenz begrenzt und Artefakte der Abtastumwandlung reduziert. Das Messsignal der Querbeschleunigung wird mit 2 Hz gefiltert. Das resultierende Signal ist in Abbildung A.4b als durchgezogene Linie dargestellt. Der gleiche Filter wird auch für die Längsbeschleunigung verwendet.

A.4 Ergänzungen zur Kullback-Leibler-Divergenz

A.4.1 Anwendbarkeit der Rule of Thumb

Die Berechnungen der Verteilungsdichtefunktionen \hat{f} in Abschnitt 4.3 basieren auf Kerndichteschätzern. Wichtiger Bestandteil des Kerndichteschätzers ist der Kern und die Bandbreitenmatrix \mathbf{H} (siehe Gleichung 2.18 und 2.19). Die Bandbreitenmatrix \mathbf{H} wird wie-



(a) Verteilungsdichte von v_x für 15 min Fahrdaten ($p = 9 \cdot 10^3$)

(b) Verteilungsdichte von v_x für 140 Std. Fahrdaten

Abbildung A.5: Vergleich verschiedener Bandbreiten w für die Berechnung der univariaten Verteilungsdichte \hat{f} mittels Kerndichteschätzer

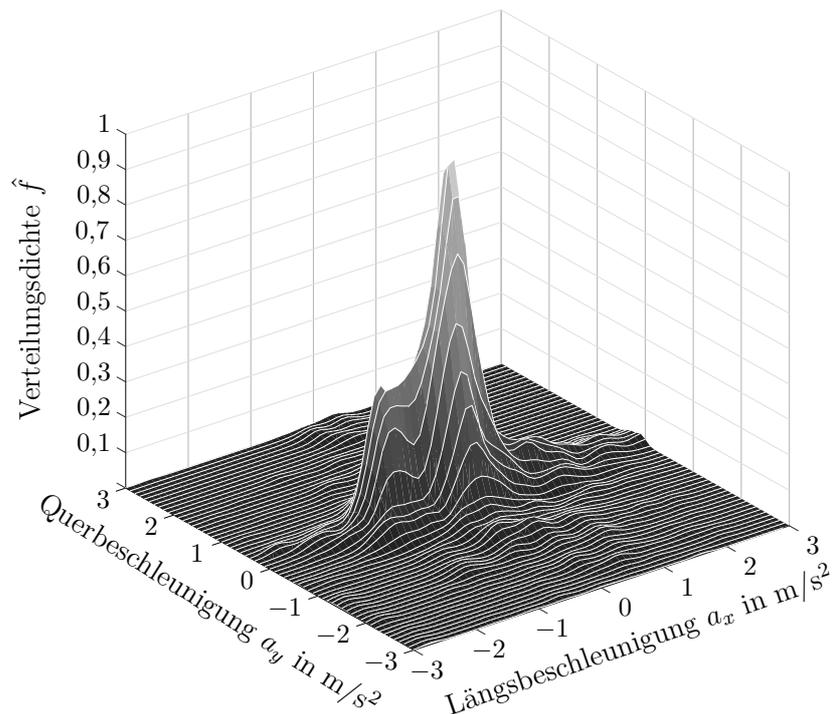


Abbildung A.6: Verteilungsdichte \hat{f} der bivariaten Verteilung von $[a_x, a_y]$ mit einer Bandbreite $w_{ROT} = [0,13; 0,08]$ für 15 min Fahrdaten

derum durch eine Bandbreite w skaliert. Die Bandbreite wird in dieser Arbeit basierend auf der *Rule of Thumb* (Abk.: ROT, siehe Gleichung 2.25) berechnet. Untersuchungen zur Bandbreitenwahl zeigen, dass die ROT nicht immer optimal ist und speziell für multimodale Verteilungen zum Überglätten (zu große Bandbreiten) neigt (JONES, J. S. MARRON et al., 1996). Infolge einer starken Glättung können Moden vollständig verschwinden. Die Gefahr der Überglättung wird mit steigender Datenmenge geringer.

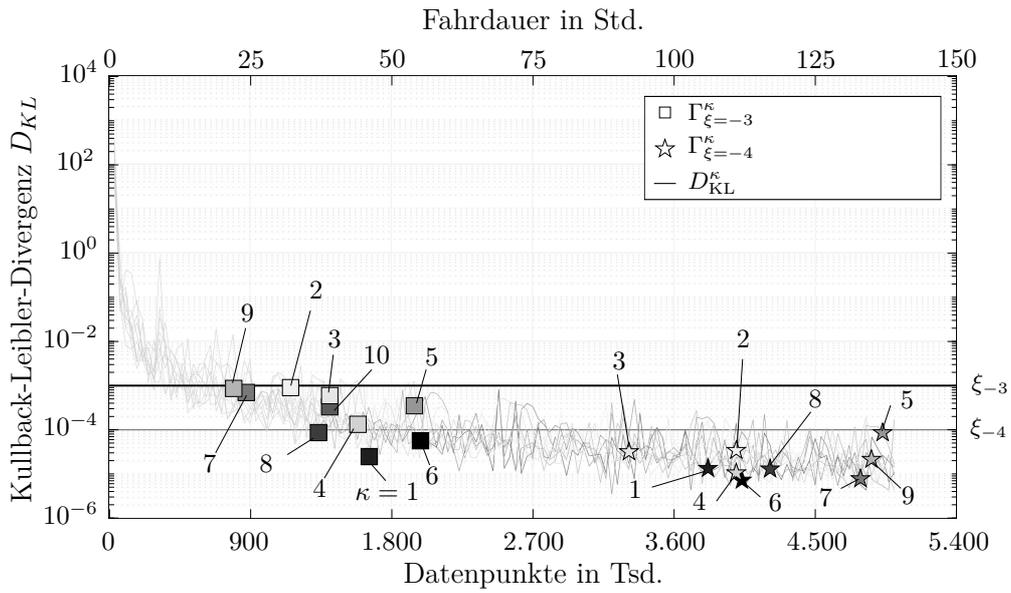
Die kleinsten Datenpakete, die zur Berechnung der Kullback-Leibler-Divergenz genutzt werden, bestehen aus $9 \cdot 10^3$ Datenpunkten bzw. 15 min. Fahrdauer. In Abbildung A.5 wird eine Gegenüberstellung für Daten aus den ersten 15 Minuten aus Sequenz Q^1 und für die vollständigen 140 Stunden dargestellt. Die Auswirkung verschiedener Bandbreiten w auf die Verteilungsdichtefunktion wird untersucht. Die Bandbreite w_{ROT} basiert auf der Berechnung der *Rule of Thumb* aus Gleichung 2.25 und ändert sich entsprechend der Datenmenge. Bereits für die kleinste untersuchte Datenmenge mit einem Umfang von $9 \cdot 10^3$ Datenpunkten (siehe Abbildung A.5a) bilden sich verschiedene Moden aus. Die Wahl der Bandbreite basierend auf der ROT erscheint optimal. Für größere Bandbreiten $w = 3$ bzw. $w = 5$ wird der Verlauf deutlich geglättet und einzelne Moden gehen verloren. Für eine deutlich kleinere Bandbreite $w = 0,1$ tendiert der Verlauf zu einer Überanpassung und schwingt. Für die vollständige Sequenz von Q^1 (siehe Abbildung A.5a) bietet die ROT eine sehr gute Wahl der Bandbreite. Ebenso zeigt die Analyse der bivariaten Vertei-

lung in Abbildung A.6 sehr gute Ergebnisse für die ROT. Die verschiedenen Moden der Verteilung werden detailliert abgebildet, sodass eine Überglättung nicht zu befürchten ist. Die Analyse der ROT ergibt, dass diese für die untersuchten Daten geeignet ist.

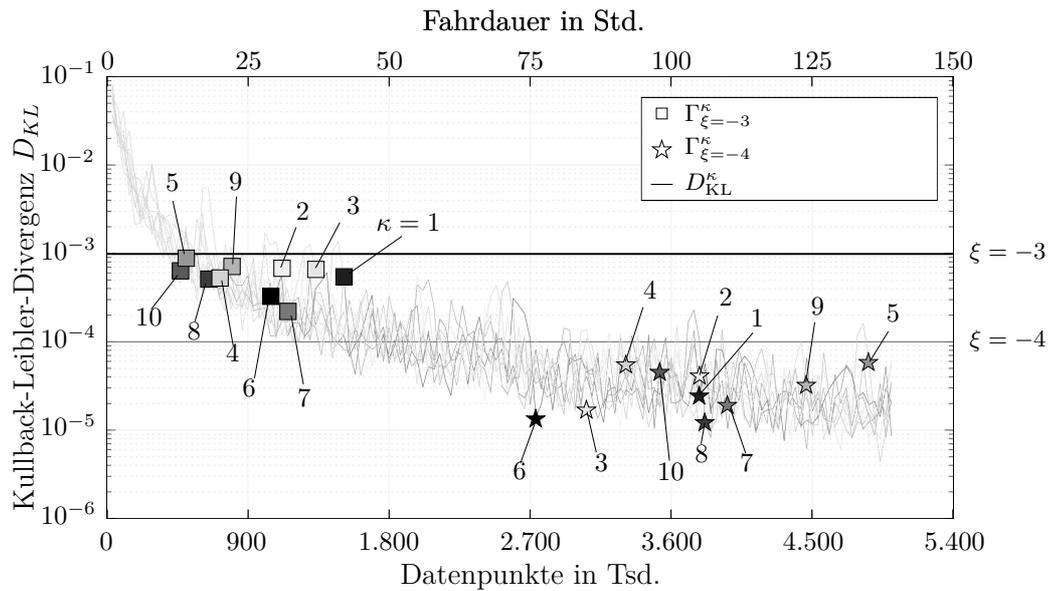
A.4.2 Kullback-Leibler-Divergenz für große Datenpakete

In Abschnitt 4.3.2 werden die Verläufe der Kullback-Leibler-Divergenz für Datenpakete der Größe $p = 9 \cdot 10^3$ bzw. 15 min. ausgewertet. Eine Auswertung für eine Datenpaketgröße von $p = 36 \cdot 10^3$ bzw. 60 min. ist in Abbildung A.7 dargestellt.

Die Verläufe der Kullback-Leibler-Divergenz für $p = 36 \cdot 10^3$ ähneln den Verläufen für $p = 9 \cdot 10^3$ aus Abbildung 4.10 qualitativ sehr. In den ersten 25 Std. der Fahrstudie ist der Informationszugewinn sehr groß und flacht zunehmend ab. Die Abbruchkriterien $\Gamma_{\epsilon=-3/4}$ sind in Abbildung A.7 mit Quadraten bzw. Sternen markiert. Die Fahrdauern, zu denen das jeweilige Abbruchkriterium erfüllt ist, weichen von denen für $p = 9 \cdot 10^3$ deutlich ab. Obwohl der Dateninhalt und folglich der Informationsinhalt für die Sequenzen \mathbf{Q}^κ aus Abbildung A.7 und 4.10 identisch sind, sind die Verläufe aufgrund der Datenpaketgröße unterschiedlich. Daher erscheint die Definition eines allgemeinen Kriteriums ϵ zum Abbruch der Messung für den vorliegenden Datensatz nicht plausibel. Gleichzeitig ist eine individuelle Auswertung des Verlaufs sinnvoll und eine Aussage hinsichtlich der Adäquanz des Datensatzes durchaus möglich. Der qualitative Verlauf wird durch die Datenpaketgröße nur minimal beeinflusst.



(a) Univariate Verteilung: Verlauf der Kullback-Leibler-Divergenz für die univariate Verteilung der Längsgeschwindigkeit v_x für eine Datenpaketgröße $p = 36 \cdot 10^3$



(b) Bivariate Verteilung: Verlauf der Kullback-Leibler-Divergenz für die bivariate Verteilung der Beschleunigungen $[a_x, a_y]$ für eine Datenpaketgröße $p = 36 \cdot 10^3$

Abbildung A.7: Auswertung der Kullback-Leibler-Divergenz für die verschiedenen Sequenzen Q^κ der Daten der Fahrstudie

A.5 Lineares Einspurmodell: Parametergrenzen der Identifikation

Eine sinnvolle Wahl der Parametergrenzen kann das Identifikationsergebnis positiv beeinflussen. Zur Festlegung werden Startparameter geschätzt und ausgehend von diesen die Grenzen bestimmt. Die Informationen zur Festlegung der Startparameter $\Theta_{ESM,0} = [m, J_z, l_v, c_{\alpha,v}, c_{\alpha,h}, i_s]$ stammen aus öffentlich zugänglichen Quellen.

Fahrzeugmasse m

Die Fahrzeugmasse kann dem Datenblatt aus Anhang A.5 entnommen werden. Das Leergewicht beträgt 1.770 kg (entspricht 3.899 lbs). Gemäß der gesetzlichen Vorgabe aus U.S. GOVERNMENT (2020) bezieht sich das Leergewicht auf das betriebsbereite Fahrzeuggewicht ohne Fahrer. Das Fahrzeuggewicht während der Fahrstudie wird folglich oberhalb des Leergewichts vermutet.

Trägheitsmoment J_z

In ALLEN et al. (2003) werden Ansätze zur Bestimmung inertialer Fahrzeugparameter vorgestellt. Der Ansatz basiert auf einem Regressionsmodell, welches einen Datensatz aus HEYDINGER, BIXEL et al. (1999) abbildet. Für das Trägheitsmoment J_z gilt:

$$J_z = 10^{k_1} \cdot l^{k_2} \cdot d_S^{k_3} \cdot d_H^{k_4} \cdot m^{k_5} \quad (\text{A.1})$$

mit: d_H = Fahrzeughöhe in ft (siehe Tabelle A.5)

d_S = mittlere Spurweite in ft (siehe Tabelle A.5)

$k_{1:5}$ = Kennwerte $(-1,7797; 1,4316; 0,3811; 0,0188; 0,98)$ aus ALLEN et al. (2003)

l = Radstand in ft (siehe Tabelle A.5)

m = Fahrzeugmasse in lbs (siehe Tabelle A.5)

Schwerpunktlage $l_{(v,h)}$

Gemäß SCHRAMM, HILLER et al. (2018) werden Fahrzeuge mit passiven Fahrwerken aus Sicherheitsaspekten üblicherweise untersteuernd ausgelegt. Eine Schwerpunktlage in Richtung der Vorderachse begünstigt dieses Verhalten. Der Radstand ist in Tabelle A.5 mit $l = 104,3 \text{ in} = 2,65 \text{ m}$ angegeben. Für die Schwerpunktlage l_v wird ein Intervall von $[1,0; 1,3] \text{ m}$ angenommen.

Schräglaufsteifigkeit $c_{\alpha,(v,h)}$

Das physikalische Verhalten der Reifen wird im Linearen Einspurmodell stark vereinfacht. Es wird ein linearer Zusammenhang aus Schräglaufsteifigkeit und Schräglaufwinkel

angenommen. Der Reifen ist aus Modellbildungssicht ein hochkomplexes System, dessen Verhalten mit physikalischen Modellen nur unter großem Aufwand abgebildet werden kann. In HEWSON (2005) wird ein Ansatz vorgestellt, mit welchem die Reifensteifigkeit auf Basis von Reifenbasisparametern geschätzt werden kann. Die Schräglaufsteifigkeit

$$c_\alpha = \frac{2c_E c_b d_w^2}{(d_r + d_w c_a)^2 \sin(\arccos(1 - \frac{c_{SW} d_w c_a}{d_r + d_w c_a})) (\pi - \sin(\arccos(1 - \frac{c_{SW} d_w c_a}{d_r + d_w c_a})))} \quad (\text{A.2})$$

mit: c_E = Kompressionsmodul des Reifengürtels ($c_E = 27 \cdot 10^6 \text{ N/m}^2$)

c_a = Verhältnis der Mantelhöhe zur Reifenbreite

c_b = Gürteldicke ($c_b = 0,015 \text{ m}$ für Straßenreifen)

c_{SW} = vertikale Seitenwanddurchbiegung bei Belastung
($c_{SW} = 0,15$ für Straßenreifen)

d_r = Reifenradius

d_w = Reifenbreite

berechnet sich für die verbauten Reifen des Typs 215/55R17 zu etwa 37 kN/rad (je Reifen). Um untersteuerndes Eigenlenkverhalten zu gewährleisten, wird die Schräglaufsteifigkeit der Reifen der Vorderachse niedriger als die der Hinterachse festgelegt.

Parameter Grenzen

Die Grenzen der Identifikation werden festgelegt zu:

$$\Theta_{ESM,0} = \begin{bmatrix} m_{min} & J_{z,min} & c_{\alpha,v,min} & c_{\alpha,h,min} & l_{v,min} & i_{S,min} \\ m_{max} & J_{z,max} & c_{\alpha,v,max} & c_{\alpha,h,max} & l_{v,max} & i_{S,max} \end{bmatrix} \quad (\text{A.3})$$

$$= \begin{bmatrix} 1800 \text{ kg} & 2200 \text{ kgm}^2 & 65 \cdot 10^3 \text{ N/rad} & 110 \cdot 10^3 \text{ N/rad} & 1,0 \text{ m} & 14,2 \\ 2000 \text{ kg} & 3200 \text{ kgm}^2 & 90 \cdot 10^3 \text{ N/rad} & 135 \cdot 10^3 \text{ N/rad} & 1,3 \text{ m} & 15,3 \end{bmatrix} \quad (\text{A.4})$$

$$(\text{A.5})$$

A.6 Ford C-Max 2013: Technische Spezifikation

Tabelle A.3: Ford C-Max 2013: Technische Spezifikation, Teil 1. Entnommen aus FORD MOTOR COMPANY (2012)

	C-Max Hybrid	C-Max Energi
BODY		
Construction	Unitized steel body	
Final assembly location	Wayne, Michigan	
POWERTRAIN AND CHASSIS		
ENGINE		
Type	2.0-liter DOHC inline four-cylinder, Atkinson cycle	2.0-liter DOHC inline four-cylinder, Atkinson cycle
Manufacturing location	Chihuahua, Mexico	Chihuahua, Mexico
Configuration	Aluminum block and head	Aluminum block and head
Valvetrain	DOHC, four valves per cylinder, intake variable camshaft timing (iVCT)	DOHC, four valves per cylinder, intake variable camshaft timing (iVCT)
Bore × stroke	87.55 mm x 83.1 mm	87.55 mm x 83.1 mm
Displacement	122 cu. in./1,999 cc	122 cu. in./1,999 cc
Compression ratio	12.3 : 1	12.3 : 1
Oil capacity	4.5 quarts with filter	4.5 quarts with filter
Coolant capacity	7 liters	8 liters
PERFORMANCE		
Engine horsepower	141 hp	141 hp
Engine torque	129 lb.-ft.	129 lb.-ft.
Total system power (sustain)	188 hp	188 hp
Top speed	115 mph	102 mph
Top speed in electric-only mode	62 mph	85 mph
EMISSIONS		
Exhaust manifold	Exhaust heat energy recapture cooled manifold	Conventional close coupled manifold
Emission control	Three-way catalyst	Three-way catalyst
Emissions level	ULEV2 (projected)	AT-PZEV (projected)

Tabelle A.4: Ford C-Max 2013: Technische Spezifikation, Teil 2. Entnommen aus FORD MOTOR COMPANY (2012)

	C-Max Hybrid	C-Max Energi
FUEL		
Fuel type	Unleaded (regular)	Unleaded (regular)
Fuel capacity	13.5 gallons	14 gallons
Fuel injection	Sequential multiport electronic	Sequential multiport electronic
Miles Per Gallon Equivalent (MPGe)	47 city/47 highway/47 combined	108 city/92 highway/100 combined
Total range	570 miles	620 miles
ELECTRIC MOTOR/GENERATOR		
Type	Permanent magnet AC synchronous motor	Permanent magnet AC synchronous motor
Output	118 hp@6,000 RPM/ 88 kW@6,000 RPM	118 hp@6,000 RPM/ 88 kW@6,000 RPM
Torque	117 lb.-ft./240 Nm	117 lb.-ft./240 Nm
TRANSMISSION		
Type	HF35 eCVT hybrid powersplit transaxle	HF35 eCVT hybrid powersplit transaxle
HIGH VOLTAGE BATTERY		
Type	1.4 kWh Lithium-ion	7.6 kWh Lithium-ion
Charge time	Applies to C-MAX Energi only	2.5 h (240 V), 7 h (120 V)
Peak power	35 kW	35 kW
SUSPENSION		
Front	Independent MacPherson strut with 25.5-mm stabilizer bar	Independent MacPherson strut with 25.5-mm stabilizer bar
Front shocks	Gas pressurized	Gas pressurized
Rear	Control Blade multilink with 22-mm stabilizer bar	Control Blade multilink with 22-mm stabilizer bar
Rear shocks	Gas pressurized	Gas pressurized
STEERING		
Type	Electric power-assisted steering (EPAS), rack-and-pinion	Electric power-assisted steering (EPAS), rack-and-pinion
Ratio	14.7 to 1	14.7 to 1
Turns, lock-to-lock	2.35	2.35
BRAKES		
Type	Power-assisted four-wheel disc brakes with four-sensor, four-channel anti-lock braking, regenerative braking system	Power-assisted four-wheel disc brakes with four-sensor, four-channel anti-lock braking, regenerative braking system
Front	278 x 25-mm vented disc	300 x 25-mm vented disc
Rear	280 x 11-mm solid disc	280 x 11-mm solid disc

Tabelle A.5: Ford C-Max 2013: Technische Spezifikation, Teil 3. Entnommen aus FORD MOTOR COMPANY (2012)

	C-Max Hybrid	C-Max Energi
WHEELS AND TIRES		
SE (C-MAX Hybrid only)	17-in. alloy, P225/50R-17	
SEL	17-in. alloy, P225/50R-17	
DIMENSIONS (inches unless otherwise noted)		
EXTERIOR		
Wheelbase	104.3	104.3
Length	173.6	173.6
Width (excluding mirrors)	72	72
Width (with mirrors)	82.1	82.1
Height	63.9	63.8
Track, front/rear	60.5/60.4	60.5/60.4
Minimum ground clearance	140mm	140mm
INTERIOR		
Seating capacity	Five	Five
First row headroom	41	41
First row legroom	40.4	40.4
First row hip room	54.3	54.3
First row shoulder room	55.9	55.9
First row hip room	54.3	54.3
Second row headroom	39.4	39.4
Second row hip room	51.9	51.9
Second row legroom	36.5	36.5
Second row shoulder room	55.2	55.2
Second row hip room	51.9	51.9
WEIGHTS AND CAPACITIES		
Base curb weight	3,640 lbs.	3,899 lbs.
Passenger volume, first row	53.7	53.7
Passenger volume, second row	46.1	46.1
Total passenger volume (cu. ft.)	99.7	99.7
Cargo volume behind first row (cu. ft.)	52.6	42.8
Cargo volume behind second row (cu. ft.)	24.5	19.2
<i>All specifications subject to change and as of Nov. 12, 2012</i>		

A.7 Ethische Aspekte einer Probandenstudie

Im Vorfeld der Fahrstudie wurden alle Teilnehmer/-innen detailliert über den Ablauf der Studie informiert. Die Studieneinwilligung jedes/-r Teilnehmers/-in ist dokumentiert. Die Datenerhebung und -speicherung ist vertraulich. Es werden keine personenbezogenen Daten erhoben, Rückschlüsse auf die Fahrerin/den Fahrer sind nicht möglich. Zur Einschätzung des Studiendesigns hinsichtlich ethischer Aspekte wird eine Checkliste von ETHIKKOMMISSION, ALLGEMEINE PSYCHOLOGIE: KOGNITION, UNIVERSITÄT DUISBURG-ESSEN (2021, S. 3) ausgefüllt. Die ausgefüllte Liste ist in Abbildung A.8 dargestellt.

	ja	nein
1. Werden an der Studie Personen teilnehmen, die nicht selbst ihre Zustimmung zur Teilnahme geben können (z. B. Personen unter 18 Jahren, Personen, die nicht im juristischen Sinne einwilligungsfähig sind)?		X
2. Werden an der Studie Personen teilnehmen, die einer besonders verletzlichen Gruppe angehören (z.B. klinische Stichproben, Personen mit Lenschwäche, Personen im Klinik- oder Strafvollzugssetting)?		X
3. Ist es erforderlich, dass Personen an der Studie teilnehmen, ohne zu diesem Zeitpunkt über ihre Teilnahme informiert zu sein bzw. ohne ihre Einwilligung gegeben zu haben (z. B. bei nicht-offener Beobachtung)?		X
4. Ist es erforderlich, dass Personen, die an der Studie teilnehmen, nicht vollständig über Zweck und Inhalt der Studie informiert werden? (Anm.: Die vollständige Information meint nicht die Offenlegung der Hypothesen, sondern bezieht sich auf den Zweck und den Ablauf der Studie. Eine nicht vollständige oder falsche Information ist beispielsweise dann gegeben, wenn eine Cover-Story nötig ist, um die Fragestellungen adressieren zu können.)		X
5. Ist es erforderlich, dass Personen aktiv über den Inhalt und den Zweck der Studie getäuscht werden?		X
6. Ist es erforderlich, Fragen zu Themen zu stellen, die für die Befragten von intimer Natur sind oder deren Beantwortung als stigmatisierend wahrgenommen werden kann (z. B. zu illegalem oder deviantem Verhalten)?		X
7. Ist zu erwarten, dass die TeilnehmerInnen durch die Studie psychischen Stress, Furcht, Erschöpfung, Schmerzen oder andere negative Effekte erleiden, die über das im Alltag zu erwartende Maß hinausgehen?		X
8. Werden den TeilnehmerInnen in der Studie Medikamente, Placebos oder andere Substanzen verabreicht?		X
9. Werden die TeilnehmerInnen der Studie irgendwelchen invasiven oder potentiell schädlichen Prozeduren unterzogen?		X
10. Werden personenbezogene Daten, die nicht in anonymisierter Form verarbeitet werden können, erhoben (z. B. Video-/Audioaufnahmen von TeilnehmerInnen, Entnahme von Körpersubstanzen wie Speichelproben)? Falls ja, welche Daten: Werden die Probanden hierüber informiert: <input type="checkbox"/> ja <input type="checkbox"/> nein Können die Probanden jederzeit die Löschung/Vernichtung dieser Daten verlangen und werden darüber informiert: <input type="checkbox"/> ja <input type="checkbox"/> nein		X
11. Wird den TeilnehmerInnen eine finanzielle Vergütung gezahlt, die deutlich einen Durchschnittsbetrag von 10 Euro <i>pro Stunde</i> überschreitet? Falls ja, wie hoch ist der Betrag? Aus welchem Grund ist es erforderlich, diesen Betrag <i>pro Stunde</i> für die Teilnahme zu bezahlen?		X

Abbildung A.8: Checkliste aus ETHIKKOMMISSION, ALLGEMEINE PSYCHOLOGIE: KOGNITION, UNIVERSITÄT DUISBURG-ESSEN (2021, S. 3)

Abbildungsverzeichnis

1.1	Einteilung von Fahrzeugdaten in unterschiedliche Klassen	2
1.2	Literaturrecherche in der Scopus-Datenbank	3
2.1	Systemanalyse nach ISERMANN (1992)	9
2.2	Ablauf einer Identifikation parametrischer Modelle	12
2.3	Signalfluss bei der Parameteridentifikation von Modellen	14
2.4	Fahrzeugbewegung im Raum nach ISO 8855	16
2.5	Grad der Versuchskontrolle von NDS und FOT	24
2.6	Komponenten einer Messkette	27
2.7	Bussysteme eines modernen Fahrzeugs	29
2.8	Aufbau eines Boxplots	34
3.1	Ablauf einer Parameteridentifikation mit NDS	47
3.2	Aufbau und Komponenten des Datenloggers der Fahrstudie	53
3.3	Abtastumsetzung auf ein äquidistantes Raster	55
3.4	Abtastumsetzung um ein rationales Verhältnis	55
3.5	Messrauschen des analogen Beschleunigungssensors	56
3.6	Einfluss der Wankbewegung auf den Messwert	57
3.7	Sensormodell für verschiedene Kombinationen der Störeinflüsse	60
4.1	Übersicht der aufgezeichneten Studiendaten im Studienzeitraum	65
4.2	Verteilung der zurückgelegten Fahrstrecken/-dauern im Studienzeitraum	66
4.3	Häufigkeitsverteilung der Längsgeschwindigkeit des Versuchsträgers	73
4.4	Vergleich der Geschwindigkeitsverteilung nach Straßentypen	74
4.5	Diagramm translatorischer Fahrzeugbeschleunigungen	76
4.6	Beschleunigungsdiagramm der Studiendaten des Versuchsträgers	78
4.7	Charakteristische Reifenkennlinie der Querkraft	79
4.8	Verteilung des Lenkradwinkels und dessen Geschwindigkeit	80
4.9	Untersuchung der Fahrdaten auf Adäquanz	83

4.10	Auswertung der Kullback-Leibler-Divergenz für Messgrößen der Studie . . .	85
4.11	Erreichen des Abbruchkriteriums	86
4.12	Aufteilung der Sequenz Q^1 in Subdatensätze S gleicher Fahrdauer	89
5.1	Definition der Systemgrenzen des Modells	92
5.2	Segmentierung in Fahrereignisse am Beispiel realer Fahrdaten	95
5.3	Häufigkeitsverteilung der Fahrdaten	96
5.4	Mathematische Betrachtung des Einspurmodells	99
5.5	Identifizierte Eigenlenkgradienten in Abhängigkeit der Datenmenge	105
5.6	Netzarchitektur zur Abbildung der Fahrzeugquerdynamik	107
5.7	Fehlerwerte für die Trainings- und Validierungsdaten der KNN	111
6.1	Verteilung relevanter Messgrößen des Validierungsmonats	118
6.2	Boxplots der RMSE-Fehlerwerte der ESM und der KNN	119
6.3	Einspurmodell: Verteilung der Residuen	122
6.4	KNN: Verteilung der Residuen	124
6.5	Einspurmodell: Validierung für einen mehrminütigen Fahrtausschnitt . . .	126
6.6	KNN: Validierung für einen mehrminütigen Fahrtausschnitt	128
6.7	Einspurmodell: Fahrmanöver Stationäre Kreisfahrt	131
6.8	KNN: Fahrmanöver Stationäre Kreisfahrt	133
6.9	bKNN: Fahrmanöver Stationäre Kreisfahrt	137
6.10	Modellvergleich für hochdynamische Kurvenfahrten	139
6.11	Fahrmanöver Doppelter Spurwechsel	141
6.12	Modellvergleich (S70, S140) für das Manöver Doppelter Spurwechsel	142
6.13	Modellvergleich (S5) für das Manöver Doppelter Spurwechsel	143
A.1	Geschwindigkeitsverteilung der Studiendaten gegenüber den GPS-Daten . .	155
A.2	Abtastraten verschiedener Messgrößen während der Fahrstudie	156
A.3	Maximaler Fehler der Abtastumsetzung	157
A.4	Verarbeitungsschritte in der Signalglättung	158
A.5	Untersuchung der Bandbreite für univariate Verteilung	159
A.6	Untersuchung der Bandbreite für die bivariate Verteilung	160
A.7	Auswertung der Kullback-Leibler-Divergenz für Messgrößen der Fahrstudie	162
A.8	Checkliste der Ethikkommission	168

Tabellenverzeichnis

2.1	Übersicht von Fahrzeugmodellen aus UNTERREINER (2014, S. 5)	19
2.2	Übersicht von nach ISO genormten Fahrmanövern für Pkw	21
2.3	Beispiele für groß angelegte Forschungsaktivitäten im Bereich NDS	26
2.4	Anwendungsbereiche und Anforderungen an Bussysteme im Kfz	30
2.5	Diagnosenachrichtenpaarung basierend auf dem UDS-Protokoll	32
4.1	Merkmale der aufgezeichneten Fahrdaten im Messzeitraum	64
4.2	Merkmale der Vergleichsstudien	69
5.1	Quantile der Messgrößen für verschiedene Fahrereignisse	97
6.1	Merkmale der Fahrdaten des Validierungsmonats	117
6.2	Fehlermetriken der verschiedenen Einspurmodelle und KNN	119
6.3	Fehlermetriken der verschiedenen bKNN	135
A.1	Komponenten des Datenloggers	153
A.2	Aufgezeichnete Fahrdynamikmessgrößen im Versuchsträger	154
A.3	Ford C-Max 2013: Technische Spezifikation, Teil 1	165
A.4	Ford C-Max 2013: Technische Spezifikation, Teil 2	166
A.5	Ford C-Max 2013: Technische Spezifikation, Teil 3	167

Literatur

- ABE, Masato (2015). *Vehicle Handling Dynamics: Theory and Application*. 2. Auflage. Oxford, Vereinigtes Königreich: Butterworth-Heinemann. ISBN: 978-0-08-100390-9.
- ALLEN, R. Wade, KLYDE, David H., ROSENTHAL, Theodore J., SMITH, David M. (2003). „Estimation of Passenger Vehicle Inertial Properties and Their Effect on Stability and Handling“. In: *SAE Transactions* 112, S. 1032–1050.
- AMMON, Dieter (2013). *Modellbildung und Systementwicklung in der Fahrzeugdynamik*. Deutschland: Vieweg+Teubner Verlag. ISBN: 978-3-663-12246-3.
- BACKER-GRØNDAHL, Agathe, PHILIPS, Ross, SAGBERG, Fridulv, TOULIOU, Katerina, GATSCHA, Michael (2009). *Topics and Applications of Previous and Current Naturalistic Driving Studies*. PROLOGUE Deliverable D1.1. Oslo, Norwegen: TØI Institute of Transport Economics.
- BAHR, Matthias, REICHERTS, Sebastian, SIEBERG, Philipp, MORSS, Luca, SCHRAMM, Dieter (2020). „Application of Artificial Neural Networks for Active Roll Control Based on Actor-Critic Reinforcement Learning“. In: *Simulation and Modeling Methodologies, Technologies and Applications*. Hrsg. von Mohammad S. OBAIDAT, Tuncer ÖREN, Helena SZCZEBICKA. SIMULTECH 2019. Advances in Intelligent Systems and Computing 1260. Springer, Cham, S. 61–82. DOI: 10.1007/978-3-030-55867-3_4.
- BAIER, Reinhold (2012). *Richtlinien für die Anlage von Stadtstraßen (RASt)*. Hrsg. von FORSCHUNGSGESELLSCHAFT FÜR STRASSEN- UND VERKEHRSWESSEN (FGSV). FGSV 200. Köln, Deutschland: FGSV-Verlag. ISBN: 978-3-939715-21-4.
- BÄRGMAN, Jonas (2015). „On the Analysis of Naturalistic Driving Data“. Abschlussarbeit. Gothenburg, Schweden: Chalmers University of Technology.

- BÄRGMAN, Jonas et al. (2017). *The UDrive Dataset and Key Analysis Results*. UDRIVE Deliverable 41.1. EU FP7 Project UDRIVE Consortium. URL: https://doi.org/10.26323/UDRIVE_D41.1.
- BARNARD, Yvonne, UTESCH, Fabian, van NES, Nicole, EENINK, Rob, BAUMANN, Martin (2016). „The Study Design of UDRIVE: The Naturalistic Driving Study across Europe for Cars, Trucks and Scooters“. In: *European Transport Research Review* 8.14. DOI: 10.1007/s12544-016-0202-z.
- BATESON, Gregory (1973). *Steps to an Ecology of Mind*. USA: HarperCollins Distribution Services. ISBN: 978-0-586-08147-1.
- BISHOP, Christopher M. (2006). *Pattern Recognition and Machine Learning*. Information Science and Statistics. Springer-Verlag New York. ISBN: 978-0-387-31073-2.
- BLUME, Sebastian, REICHERTS, Sebastian, DRIESCH, Patrick, SCHWEIG, Stephan, SCHRAMM, Dieter (2018). „Identifizierung von Range Extender Fahrten anhand realer Bewegungsprofile durch künstliche neuronale Netze“. In: *Mobilität und digitale Transformation*. Hrsg. von Heike PROFF, Thomas M. FOJCIK. Springer Gabler, Wiesbaden. DOI: 10.1007/978-3-658-20779-3_15.
- BLUME, Sebastian, SIEBERG, Philipp M., MAAS, Niko, SCHRAMM, Dieter (2019). „Neural Roll Angle Estimation in a Model Predictive Control System“. In: *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*. Auckland, Neuseeland, S. 1625–1630. DOI: 10.1109/ITSC.2019.8917106.
- BRAESS, Hans-Hermann, SEIFFERT, Ulrich, Hrsg. (2013). *Vieweg Handbuch Kraftfahrzeugtechnik*. ATZ/MTZ-Fachbuch. Springer Vieweg, Wiesbaden. DOI: 10.1007/978-3-658-01691-3.
- BUNDESMINISTERIUM FÜR VERKEHR UND DIGITALE INFRASTRUKTUR (BMVI) (2008). *Mobilität in Deutschland - MiD 2008 - Ergebnisbericht*. URL: <https://www.bmvi.de/SharedDocs/DE/Artikel/G/mobilitaet-in-deutschland.html> (besucht am 14.11.2020).
- BUNDESMINISTERIUM FÜR VERKEHR UND DIGITALE INFRASTRUKTUR (BMVI) (2017). *Mobilität in Deutschland - MiD 2017 - Ergebnisbericht*. URL: <https://www.bmvi.de/SharedDocs/DE/Artikel/G/mobilitaet-in-deutschland.html> (besucht am 14.11.2020).
- CAPGEMINI INVENT, WINKLER, Markus, MEHL, Rainer, MATTHIES, Marc, MONSKE, Simon (2020). *Monetizing Vehicle Data: How to Fulfill the Promise*. Capgemini

- invent. URL: <https://www.capgemini.com/resources/monetizing-vehicle-data/> (besucht am 21. 10. 2020).
- CARSTEN, Oliver, KIRCHER, Katja, JAMSON, Samantha (2013). „Vehicle-Based Studies of Driving in the Real World: The Hard Truth?“ In: *Accident Analysis & Prevention* 58, S. 162–174. DOI: 10.1016/j.aap.2013.06.006.
- CERONE, Vito, PIGA, Dario, REGRUTO, Diego (2011). „Set-Membership LPV Model Identification of Vehicle Lateral Dynamics“. In: *Automatica* 47.8, S. 1794–1799. DOI: 10.1016/j.automatica.2011.04.016.
- CHECKLAND, Peter, SCHOLE, Jim (1990). *Soft Systems Methodology in Action*. New York, USA: John Wiley & Sons, Inc. 329 S. ISBN: 978-0-471-92768-6.
- CHOLLET, François (2018). *Deep Learning with Python*. New York, USA: Manning Publications Co. ISBN: 978-1-61729-443-3.
- CROCHIERE, Ronald E., RABINER, Lawrence R. (1983). *Multirate Digital Signal Processing*. New Jersey, USA: Prentice-Hall. ISBN: 978-0-13-605162-6.
- CTS-ChinaFOT (2020). Vinnova. URL: <https://www.vinnova.se/en/p/cts-chinafot/> (besucht am 07. 10. 2020).
- CURRIE, Roderick (2017). *Hacking the CAN Bus: Basic Manipulation of a Modern Automobile Through CAN Bus Reverse Engineering*. URL: <https://www.sans.org/reading-room/whitepapers/threats/hacking-bus-basic-manipulation-modern-automobile-through-bus-reverse-engineering-37825> (besucht am 19. 08. 2020).
- DA LIO, Mauro, BORTOLUZZI, Daniele, ROSATI PAPINI, Gastone Pietro (2020). „Modeling Longitudinal Vehicle Dynamics with Neural Networks“. In: *Vehicle System Dynamics* 58.11, S. 1675–1693. DOI: 10.1080/00423114.2019.1638947.
- DACHROTH, Wolfgang R. (1992). „Straßenbau“. In: *Baugeologie*. Springer, Berlin, Heidelberg. DOI: 10.1007/978-3-642-97393-2_4.
- DEUTSCHES INSTITUT FÜR NORMUNG E. V. (DIN) (1995). *1319-1: Grundlagen der Meßtechnik, Teil 1: Grundbegriffe*.
- DING, Eve. L., MASSEL, Thomas (2005). „Estimation of Vehicle Roll Angle“. In: *IFAC Proceedings Volumes* 38.1, S. 122–127. DOI: 10.3182/20050703-6-CZ-1902.01908.

- DINGUS, Thomas et al. (2006). *The 100-Car Naturalistic Driving Study: Phase II – Results of the 100-Car Field Experiment*. Report DOT-HS-810-593. USA: Virginia Tech Transportation Institute.
- DREAMS4CARS (2017). *Dream-like Simulation Abilities for Automated Cars*. European Commission, Horizon 2020.
- DRIESCH, Patrick, WEISSKOPF, Torben, SCHRAMM, Dieter (2020). „Entwicklung repräsentativer Prüfzyklen für mobile Maschinen auf Grundlage realer Felddaten“. In: 6. IF-ToMM D-A-CH Konferenz 2020. Lienz, Österreich. DOI: 10.17185/DUEPUBLICO/71201.
- EBERHART, Russell, KENNEDY, James (1995). „A New Optimizer Using Particle Swarm Theory“. In: *Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. Nagoya, Japan: IEEE, S. 39–43. DOI: 10.1109/MHS.1995.494215.
- ETHIKKOMMISSION, ALLGEMEINE PSYCHOLOGIE: KOGNITION, UNIVERSITÄT DUISBURG-ESSEN (2021). *Begutachtung von Forschungsvorhaben durch die Ethikkommission der Abteilung für Informatik und Angewandte Kognitionswissenschaft*. URL: https://www.uni-due.de/imperia/md/content/kognitionspsychologie/basisfragebogen_10_07_12.pdf (besucht am 13.03.2021).
- FABER, Freek et al. (2012). *Final Results: Impacts on Traffic Efficiency and Environment*. Deliverable D6.5 & 6.6. Aachen, Deutschland: Ford Research & Advanced Engineering Europe.
- FIELD OPERATIONAL TEST NETWORKING AND METHODOLOGY PROMOTION (FOT-NET), COORDINATION OF AUTOMATED ROAD TRANSPORT DEPLOYMENT FOR EUROPE (CARTRE) (2008). *Data Requirements for FOT Methodology*. Deliverable 2.2. Brüssel, Belgien: European Commission.
- FIELD OPERATIONAL TEST NETWORKING AND METHODOLOGY PROMOTION (FOT-NET), COORDINATION OF AUTOMATED ROAD TRANSPORT DEPLOYMENT FOR EUROPE (CARTRE) (2018). *FESTA Handbook Version 7*. Brüssel, Belgien: European Commission.
- FLORIDI, Luciano (2005). „Is Semantic Information Meaningful Data?“ In: *Philosophy and Phenomenological Research* 70.2, S. 351–370. DOI: 10.1111/j.1933-1592.2005.tb00531.x.
- FORD MOTOR COMPANY (2012). *Ford C-MAX Energi 2013 Technical Specifications*. URL: https://web.archive.org/web/20121203201928/http://media.ford.com/images/10031/2013_CMAX_Specs.pdf (besucht am 07.05.2019).

- GERS, Felix, SCHMIDHUBER, Jürgen (2000). „Recurrent Nets That Time and Count“. In: Proceedings of the International Joint Conference on Neural Networks. IJCNN 2000. Bd. 3, S. 189–194. DOI: 10.1109/IJCNN.2000.861302.
- GERS, Felix, SCHMIDHUBER, Jürgen, CUMMINS, Fred (2000). „Learning to Forget: Continual Prediction with LSTM“. In: *Neural Computation* 12.10, S. 2451–2471. DOI: 10.1162/089976600300015015.
- GIAKOUMIS, Evangelos G. (2017). *Driving and Engine Cycles*. Springer, Cham. DOI: 10.1007/978-3-319-49034-2.
- GILLESPIE, Thomas D. (1992). *Fundamentals of Vehicle Dynamics*. Warrendale, USA: Society of Automotive Engineers. DOI: 10.4271/R-114.
- GRÄBER, Torben, LUPBERGER, Stefan, UNTERREINER, Michael, SCHRAMM, Dieter (2019). „A Hybrid Approach to Side-Slip Angle Estimation With Recurrent Neural Networks and Kinematic Vehicle Models“. In: *IEEE Transactions on Intelligent Vehicles* 4.1, S. 39–47. DOI: 10.1109/TIV.2018.2886687.
- GUTH, Dominik, REICHERTS, Sebastian, SCHRAMM, Dieter, SCHMUCK, Christian (2021). „Modulares Regelungskonzept für die reproduzierbare Fahrzeugführung in Prüfscenarien“. In: *Making Connected Mobility Work*. Duisburg, Deutschland, S. 691–705. DOI: 10.1007/978-3-658-32266-3_43.
- HAHN, Jin-oh, RAJAMANI, Rajesh, YOU, Seung-Han, LEE, Kyo Il (2004). „Real-Time Identification of Road-Bank Angle Using Differential GPS“. In: *IEEE Transactions on Control Systems Technology* 12.4, S. 589–599. DOI: 10.1109/TCST.2004.825131.
- HALFMANN, Christoph (2001). *Adaptive semiphysikalische Echtzeitsimulation der Kraftfahrzeugdynamik im bewegten Fahrzeug*. Bd. 467. Fortschritt-Berichte VDI 12. Düsseldorf, Deutschland: VDI Verlag. ISBN: 978-3-18-346712-9.
- HALFMANN, Christoph, HOLZMANN, Henning (2003). *Adaptive Modelle für die Kraftfahrzeugdynamik*. VDI-Buch. Springer-Verlag Berlin Heidelberg. DOI: 10.1007/978-3-642-18215-0.
- HANKEY, Jonathan M (2014). „Overview of the Canada NDS and the Canada Truck NDS“ (Saskatchewan, Kanada). URL: <https://www.vtti.vt.edu/PDFs/ndrs-2014/Hankey-2014.pdf>.
- HARNACK, Nele, REICHERTS, Sebastian, BLUME, Sebastian, SIEBERG, Philipp M. (2018). „Entwicklung und Validierung eines Simulationsmodells zur Abbildung der Gesamtfahrzeugdynamik mit Hilfe von LSTM-Zellen“. In: Conference: 10. Wissenschaftsforum

- Mobilität 2018: Mobility in Times of Change - Past, Present, Future. Duisburg, Deutschland.
- HEISSING, Bernd, ERSOY, Metin, GIES, Stefan, Hrsg. (2011). *Fahrwerkhandbuch: Grundlagen, Fahrdynamik, Komponenten, Systeme, Mechatronik, Perspektiven*. 3. Aufl. ATZ/MTZ-Fachbuch. Vieweg+Teubner. URL: <https://doi.org/10.1007/978-3-8348-8168-7>.
- HEWSON, Peter (2005). „Method for Estimating Tyre Cornering Stiffness from Basic Tyre Information“. In: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 219.12, S. 1407–1412. DOI: 10.1243/095440705X35071.
- HEYDINGER, Gary J., BIXEL, Ronald A., GARROTT, W. Riley, PYNE, Michael, HOWE, J. Gavin, GUENTHER, Dennis A. (1999). „Measured Vehicle Inertial Parameters-NHTSA’s Data Through November 1998“. In: SAE Technical Paper. DOI: 10.4271/1999-01-1336.
- HEYDINGER, Gary J., GARROTT, W. Riley, CHRSTOS, Jeffrey P., GUENTHER, Dennis A. (1990). „A Methodology for Validating Vehicle Dynamics Simulations“. In: SAE Technical Paper. DOI: 10.4271/900128.
- HOCHREITER, Sepp, SCHMIDHUBER, Jürgen (1997). „Long Short-term Memory“. In: *Neural computation* 9.8, S. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
- HOHN, Maximilian (2021). „Entwicklung und Validierung einer Methode zur Abbildung der Fahrzeugdynamik mit Künstlichen Neuronalen Netzen“. Abschlussarbeit. Duisburg, Deutschland: Universität Duisburg-Essen. DOI: 10.17185/duepublico/74076.
- HOLZMANN, Henning (2001). *Adaptive Kraftfahrzeugdynamik-Echtzeitsimulation mit hybriden Modellen*. Bd. 465. Fortschritt-Berichte VDI Reihe 12. Düsseldorf, Deutschland: VDI Verlag. ISBN: 978-3-18-346512-5.
- HOLZMANN, Henning, NELLES, Oliver, HALFMANN, Christoph, ISERMANN, Rolf (1999). „Vehicle Dynamics Simulation Based on Hybrid Modeling“. In: *1999 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, S. 1014–1019. DOI: 10.1109/AIM.1999.803311.
- HUYBRECHTS, Thomas, VANOMMESLAEGHE, Yon, BLONTROCK, Dries, VAN BAREL, Gregory, HELLINCKX, Peter (2018). „Automatic Reverse Engineering of CAN Bus Data Using Machine Learning Techniques“. In: *Advances on P2P, Parallel, Grid, Cloud and Internet Computing*. Hrsg. von Fatos XHAFA, Santi CABALLÉ, Leonard BAROLLI. Bd. 13. Springer Cham. DOI: 10.1007/978-3-319-69835-9_71.

-
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (1999). *14512-1: Passenger Cars - Straight-ahead Braking on Surfaces with Split Coefficient of Friction - Open-loop Test Method.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2006). *7975: Passenger Cars - Braking in a Turn - Open-loop Test Method.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2007). *21994: Passenger Cars - Stopping Distance at Straight-Line Braking with ABS - Open-loop Test Method.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2010a). *12021: Road Vehicles - Sensitivity to Lateral Wind - Open-loop Test Method Using Wind Generator Input.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2010b). *13674-2: Road Vehicles - Test Method for the Quantification of on-Centre Handling - Part 2: Transition Test.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2011a). *15765-1: Road Vehicles - Diagnostic Communication over Controller Area Network (DoCAN) - Part 1: General Information and Use Case Definition.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2011b). *17288-1: Passenger Cars - Free-steer Behaviour - Part 1: Steering-release Open-Loop Test Method.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2011c). *17288-2: Passenger Cars - Free-steer Behaviour - Part 2: Steering-pulse Open-Loop Test Method.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2011d). *3888-2: Passenger Cars - Test Track for a Severe Lane-Change Manoeuvre - Part 2: Obstacle Avoidance.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2011e). *7401: Road Vehicles - Lateral Transient Response Test Methods - Open-loop Test Methods.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2012). *4138: Passenger Cars - Steady-state Circular Driving Behaviour - Open-loop Test Methods.*
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2013a). *14229-1: Road Vehicles - Unified Diagnostic Services (UDS) - Part 1: Specification and Requirements.*

- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2013b). *8855: Road Vehicles - Vehicle Dynamics and Road-Holding Ability*.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2015). *15031-5: Road Vehicles - Communication between Vehicle and External Equipment for Emissions-Related Diagnostics - Part 5: Emissions-related Diagnostic Services*.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2016). *13674-1: Road Vehicles - Test Method for the Quantification of on-Centre Handling - Part 1: Weave Test*.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2018a). *3888-1: Passenger Cars - Test Track for a Severe Lane-Change Manoeuvre - Part 1: Double Lane-Change*.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2018b). *9816: Passenger Cars - Power-off Reaction of a Vehicle in a Turn - Open-loop Test Method*.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO) (2019). *15037-1: Road Vehicles — Vehicle Dynamics Test Methods*.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO/TS) (2002). *20119: Road Vehicles - Test Method for the Quantification of on-Centre Handling - Determination of Dispersion Metrics for Straight-Line Driving*.
- ISERMANN, Rolf (1992). *Identifikation dynamischer Systeme 1*. Springer Berlin Heidelberg. DOI: 10.1007/978-3-642-84679-3.
- ISERMANN, Rolf, MÜNCHHOF, Marco (2011). *Identification of Dynamic Systems*. Springer Berlin Heidelberg. DOI: 10.1007/978-3-540-78879-9.
- JAMES, Sebastian, ANDERSON, Sean R. (2018). „Linear System Identification of Longitudinal Vehicle Dynamics Versus Nonlinear Physical Modelling“. In: *2018 UKACC 12th International Conference on Control (CONTROL)*. Sheffield, Vereinigtes Königreich: IEEE, S. 146–151. DOI: 10.1109/CONTROL.2018.8516756.
- JAMES, Sebastian, ANDERSON, Sean R., DA LIO, Mauro (2020). „Longitudinal Vehicle Dynamics: A Comparison of Physical and Data-Driven Models Under Large-Scale Real-World Driving Conditions“. In: *IEEE Access* 8, S. 73714–73729. DOI: 10.1109/ACCESS.2020.2988592.
- JOHNSON, Justin M., KHOSHGOFTAAR, Taghi M. (2019). „Survey on Deep Learning with Class Imbalance“. In: *Journal of Big Data* 6.27. DOI: 10.1186/s40537-019-0192-5.

- JONES, M. Chris, MARRON, J., SHEATHER, S. (1996). „A Brief Survey of Bandwidth Selection for Density Estimation“. In: *Journal of the American Statistical Association* 91.433, S. 401–407. DOI: 10.2307/2291420.
- JONES, M. Chris, MARRON, James S., SHEATHER, Simon J. (1996). „Progress in Data-Based Bandwidth Selection for Kernel Density Estimation“. In: *Computational Statistics* 11, S. 337–381.
- JUN, Jungwook, GUENSLER, Randall, OGLE, Jennifer H. (2006). „Smoothing Methods to Minimize Impact of Global Positioning System Random Error on Travel Distance, Speed, and Acceleration Profile Estimates“. In: *Transportation Research Record: Journal of the Transportation Research Board* 1972.1, S. 141–150. DOI: 10.1177/0361198106197200117.
- KENNEDY, James, EBERHART, Russell (1995). „Particle Swarm Optimization“. In: *Proceedings of ICNN'95 - International Conference on Neural Networks*. Bd. 4. Perth, Australien: IEEE, S. 1942–1948. DOI: 10.1109/ICNN.1995.488968.
- KINGMA, Diederik P., BA, Jimmy (2017). *Adam: A Method for Stochastic Optimization*. arXiv: 1412.6980. URL: <http://arxiv.org/abs/1412.6980> (besucht am 19.02.2021).
- KLAUER, Sheila, DINGUS, Thomas, NEALE, T, SUDWEEKS, J., RAMSEY, D (2006). *The Impact of Driver Inattention on Near-Crash/Crash Risk: An Analysis Using the 100-Car Naturalistic Driving Study Data*. Report DOT HS 810 594. USA: Virginia Tech Transportation Institute.
- KOHN, Wolfgang (2005). *Statistik: Datenanalyse und Wahrscheinlichkeitsrechnung*. Statistik und ihre Anwendungen. Springer-Verlag Berlin Heidelberg. ISBN: 978-3-540-21677-3.
- KONISHI, Sadanori, KITAGAWA, Genshiro (2008). *Information Criteria and Statistical Modeling*. Springer Series in Statistics. Springer-Verlag New York. DOI: 10.1007/978-0-387-71887-3.
- KOPPERS, Martin (2018). „Ein methodischer Ansatz zur nutzerspezifischen Bewertung von (teil-)elektrischen Fahrzeugkonzepten“. Diss. Duisburg, Deutschland: Universität Duisburg-Essen. DOI: 10.17185/dupublico/48073.
- KRACHT, Frédéric E. (2020). „Modellbildung und Simulation der Dynamik und Elastokinematik von Radaufhängungen für Echtzeitanwendungen“. Diss. Duisburg, Deutschland: Universität Duisburg-Essen. DOI: 10.17185/DUEPUBLICO/71445.
- KRAFTFAHRT-BUNDESAMT (2020). *Verkehr in Kilometern - Inländerfahrleistung*. kba.de. URL: https://www.kba.de/DE/Statistik/Kraftverkehr/VerkehrKilometer/vk_

- inlaenderfahrleistung/vk_inlaenderfahrleistung_inhalt.html (besucht am 11. 11. 2020).
- KULLBACK, Solomon (1978). *Information Theory and Statistics*. USA: Courier Corporation. ISBN: 0-8446-5625-9.
- KULLBACK, Solomon, LEIBLER, Richard A. (1951). „On Information and Sufficiency“. In: *The Annals of Mathematical Statistics* 22.1, S. 79–86. DOI: 10.1214/aoms/1177729694.
- KUMAR, Pradeep, RADHA KRISHNA, P., RAJU, S. Bapi, Hrsg. (2012). *Pattern Discovery Using Sequence Data Mining: Applications and Studies*. Hershey, USA: Information Science Reference. DOI: 10.4018/978-1-61350-056-9.
- LEWIS, Vicki, KLAUER, Sheila, KNIPLING, Ronald, DINGUS, Thomas, HOLBROOK, G, PETERSEN, Andrew (2002). *The 100-Car Naturalistic Driving Study: Phase I – Experimental Design*. Report DOT HS 809 536. USA: Virginia Tech Transportation Institute.
- LIETZ, Holger et al. (2011). *Methodische und technische Aspekte einer Naturalistic Driving Study*. FAT Schriftenreihe 229.
- LIU, Rui, ZHU, Xichan (2017). „Driving Data Distribution of Human Drivers in Urban Driving Condition“. In: *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*. 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), S. 1–6. DOI: 10.1109/ITSC.2017.8317703.
- LIU, Rui, ZHU, Xichan (2019). *Statistical Characteristics of Driver Accelerating Behavior and Its Probability Model*. URL: <https://arxiv.org/abs/1907.01747> (besucht am 03. 04. 2020).
- LIU, Rui, ZHU, Xichan, LIU, Lin, WU, Biao (2018). „Personalized and Common Acceleration Distribution Characteristic of Human Driver“. In: *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, S. 1820–1825. DOI: 10.1109/ITSC.2018.8569942.
- LJUNG, Lennart (1987). *System Identification: Theory for the User*. Englewood Cliffs, USA: Prentice-Hall. ISBN: 978-0-13-881640-7.
- MALFABON, Rudy, LARSON, Sandra, GEE, King, PROCTOR, Gordon (2014). „Overview of SHRP2 Safety Implementation“. Safety Task Force Meeting and Implementation Workshop (Washington, D.C.).
- MARVASTI, Farokh (2001). *Nonuniform Sampling: Theory and Practice*. Boston, MA: Springer US. ISBN: 978-1-4613-5451-2 978-1-4615-1229-5.

- MCKINSEY&COMPANY et al. (2016). *Monetizing Car Data - New Service Business Opportunities to Create New Customer Benefits*. New York, USA: McKinsey&Company. URL: <https://www.mckinsey.com/industries/automotive-and-assembly/our-insights/monetizing-car-data#> (besucht am 21.10.2020).
- MERTINS, Alfred (2020). *Signaltheorie: Grundlagen der Signalbeschreibung, Filterbänke, Wavelets, Zeit-Frequenz-Analyse, Parameter- und Signalschätzung*. Springer Vieweg, Wiesbaden. DOI: 10.1007/978-3-658-29648-3.
- METZ, Barbara, LANDAU, Andreas, HARGUTT, Volker, NEUKUM, Alexandra (2013). *Naturalistic Driving Data - Re-Analyse von Daten aus dem EU-Projekt euroFOT*. FAT Schriftenreihe 265.
- METZ, Barbara, LANDAU, Andreas, HARGUTT, Volker, NEUKUM, Alexandra (2014). „Naturalistische Fahrverhaltensbeobachtungen - Ergebnisse zum Telefonieren beim Fahren“. In: *ATZ Automobiltech Z* 116, S. 72–77. DOI: 10.1007/s35148-014-0455-6.
- MILANES, Vicente, SHLADOVER, Steven E., SPRING, John, NOWAKOWSKI, Christopher, KAWAZOE, Hiroshi, NAKAMURA, Masahide (2014). „Cooperative Adaptive Cruise Control in Real Traffic Situations“. In: *IEEE Transactions on Intelligent Transportation Systems* 15.1, S. 296–305. DOI: 10.1109/TITS.2013.2278494.
- MILLIKEN, William F., MILLIKEN, Douglas L. (1995). *Race Car Vehicle Dynamics*. Warrendale, USA: SAE International. ISBN: 978-1-56091-526-3.
- MITSCHEKE, Manfred (2005). „Das Einspurmodell von Riekert-Schunck“. In: *ATZ Automobiltech Z* 107, S. 1030–1031. DOI: 10.1007/BF03223515.
- MITSCHEKE, Manfred, WALLENTOWITZ, Henning (2004). *Dynamik der Kraftfahrzeuge*. Springer, Berlin, Heidelberg. DOI: 10.1007/978-3-662-06802-1.
- NELLES, Oliver (2011). *Nonlinear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models*. Springer-Verlag Berlin Heidelberg. ISBN: 978-3-642-08674-8.
- NERDINGER, Friedemann W., BLICKLE, Gerhard, SCHAPER, Niclas (2008). *Arbeits- und Organisationspsychologie*. Springer-Verlag Berlin Heidelberg. DOI: 10.1007/978-3-540-74705-5.
- O’SHEA, Peter, SADIK, Amin Z., HUSSAIN, Zahir M. (2011). *Digital Signal Processing*. Springer, Berlin, Heidelberg. DOI: 10.1007/978-3-642-15591-8.

- OLAH, Christopher (2015). *Understanding LSTM Networks*. colah's blog. URL: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (besucht am 01.02.2021).
- PACEJKA, Hans B. (2006). *Tire and Vehicle Dynamics*. 2. Aufl. Oxford, Vereinigtes Königreich: Elsevier/BH. ISBN: 980-0-7506-6918-4.
- RAHIM, Lawan, BLUME, Sebastian, REICHERTS, Sebastian, SIEBERG, Philipp M., SCHRAMM, Dieter (2019). „Zustandsschätzung des Wankverhaltens von Personenkraftwagen mittels künstlicher neuronaler Netze“. In: *Mobilität in Zeiten der Veränderung*. Hrsg. von Heike PROFF. Springer Gabler, Wiesbaden, S. 229–239. DOI: 10.1007/978-3-658-26107-8_17.
- REGAN, Michael et al. (2013). „The Australian 400-Car Naturalistic Driving Study: Innovation in Road Safety Research and Policy“. In: *Proceedings of the Road Safety Research, Policing and Enforcement Conference*. Brisbane, Australien.
- REHM, Ansgar (2010). „Estimation of Vehicle Roll Angle“. In: *2010 4th International Symposium on Communications, Control and Signal Processing (ISCCSP)*. Limassol, Zypern. DOI: 10.1109/ISCCSP.2010.5463458.
- REICHERTS, Sebastian, HESSE, Benjamin, SCHRAMM, Dieter (2021). „Use of Naturalistic Driving Studies for Identification of Vehicle Dynamics“. In: *IEEE Open Journal of Intelligent Transportation Systems*, S. 1–12. ISSN: 2687-7813. DOI: 10.1109/OJITS.2021.3093712.
- REICHERTS, Sebastian, SCHRAMM, Dieter (2020). „Parameter Identification of Vehicle Dynamics Models Using CAN Communication on Real-life Driving Data“. In: *AmE 2020 - Automotive Meets Electronics; 11th GMM-Symposium*. Dortmund, Deutschland: VDE. ISBN: 978-3-8007-5202-7.
- REIF, Konrad, Hrsg. (2016). *Sensoren im Kraftfahrzeug*. Springer Vieweg, Wiesbaden. DOI: 10.1007/978-3-658-11211-0.
- RICE, Roy S. (1973). „Measuring Car-Driver Interaction with the g-g Diagram“. In: 1973 International Automotive Engineering Congress and Exposition. USA: SAE International. DOI: 10.4271/730018.
- RIEGL, Peter, GAULL, Andreas (2018). „Modeling and Validation of a Complex Vehicle Dynamics Model for Real-time Applications:“. In: *Proceedings of 8th International Conference on Simulation and Modeling Methodologies, Technologies and Applications*. Porto, Portugal: SCITEPRESS - Science and Technology Publications, S. 403–413. DOI: 10.5220/0006856304030413.

- RIEKERT, Paul, SCHUNCK, Theo-Ernst (1940). „Zur Fahrmechanik des gummibereiften Kraftfahrzeugs“. In: *Ingenieur-Archiv* 11.3, S. 210–224. DOI: 10.1007/BF02086921.
- ROHLOFF, Michael (2008). *Richtlinien für die Anlage von Autobahnen (RAA)*. Hrsg. von FORSCHUNGSGESELLSCHAFT FÜR STRASSEN- UND VERKEHRSWESEN (FGSV). FGSV 202. Köln, Deutschland: FGSV-Verl. ISBN: 978-3-939715-51-1.
- ROKICKI, Krzysztof, SZCZUROWSKI, Krzysztof (2015). „Methods of Identification of Data Transmitted in the In-Vehicle CAN-BUS Networks“. In: *2015 20th International Conference on Methods and Models in Automation and Robotics (MMAR)*. Miedzyzdroje, Poland, S. 946–949. DOI: 10.1109/MMAR.2015.7284005.
- SAGBERG, Fridulv, EENINK, Rob, HOEDEMAEKER, Marika, LOTAN, Tsippy, van NES, Nicole, SMOKERS, Richard, WELSH, Ruth, WINKELBAUER, Martin (2011). *Recommendations for a Large-Scale European Naturalistic Driving Observation Study*. PROLOGUE Deliverable D4.1. Oslo, Norwegen: TØI Institute of Transport Economics.
- SCHOCH, Stefanie et al. (2011). *Final Delivery of Data and Answers to Questionnaires*. euroFOT Deliverable D5.3. Aachen, Deutschland: Ford Research & Advanced Engineering Europe, S. 142.
- SCHRAMM, Dieter, DUDENHÖFFER, Ferdinand, DRIESCH, Patrick, KANNSTÄTTER, Timm (2017). *Plug-In-, Range-Extender- und Elektrofahrzeuge unter realen Mobilitätsumständen: Infrastruktur, Umweltbedingungen und Marktakzeptanz*. Schlussbericht. Duisburg, Deutschland: Universität Duisburg-Essen. DOI: 10.2314/GBV:1011140942.
- SCHRAMM, Dieter, HILLER, Manfred, BARDINI, Roberto (2018). *Vehicle Dynamics*. Springer, Berlin, Heidelberg. ISBN: 978-3-662-54482-2 978-3-662-54483-9. DOI: 10.1007/978-3-662-54483-9.
- SCHÜLLER, Mira (2019). „Technisch optimale Auslegung von Elektrofahrzeugen für Nutzergruppen in China und Deutschland: eine vergleichende Untersuchung“. Diss. Duisburg, Deutschland: Universität Duisburg-Essen. DOI: 10.17185/DUEPUBLIC0/70538.
- SHANNON, Claude E. (1948). „A Mathematical Theory of Communication“. In: *Bell System Technical Journal* 27.3, S. 379–423. DOI: 10.1002/j.1538-7305.1948.tb01338.x.
- SIEBERG, Philipp M., BLUME, Sebastian, REICHERTS, Sebastian, SCHRAMM, Dieter (2019). „Nichtlineare modellbasierte prädiktive Regelung der Fahrzeugdynamik in Bezug auf eine aktive Wankstabilisierung und eine Nickreduzierung“. In: *Forschung im Ingenieurwesen* 83, S. 119–127. DOI: 10.1007/s10010-019-00337-6.

- SILVER, Gerald A., SILVER, Myrna (1989). *Systems Analysis and Design*. Addison-Wesley Pub. Co. ISBN: 978-0-201-06615-9.
- SILVERMAN, Bernard W. (1998). *Density Estimation for Statistics and Data Analysis*. Monographs on Statistics and Applied Probability 26. USA: Chapman & Hall/CRC. 175 S. ISBN: 978-0-412-24620-3.
- SÖDERSTRÖM, Torsten, STOICA, Petre (1989). *System Identification*. Prentice Hall International Series in Systems and Control Engineering. New York, USA: Prentice Hall International. ISBN: 978-0-13-881236-2.
- STRATEGIC HIGHWAY RESEARCH PROGRAM 2 (SHRP 2) (2015). Transportation Research Board (TRB). URL: <http://www.trb.org/StrategicHighwayResearchProgram2SHRP2/Blank2.aspx> (besucht am 17.04.2020).
- STRUTZ, Tilo (2011). *Data Fitting and Uncertainty: A Practical Introduction to Weighted Least Squares and Beyond*. Wiesbaden, Deutschland: Vieweg + Teubner. ISBN: 978-3-8348-1022-9.
- TEWIELE, Sarah (2020). „Generierung von repräsentativen Fahr- und Lastzyklen aus realen Fahrdaten batterieelektrischer Fahrzeuge“. Diss. Duisburg, Deutschland: Universität Duisburg-Essen. DOI: 10.17185/dupublico/72728.
- TSENG, H. Eric (2001). „Dynamic Estimation of Road Bank Angle“. In: *Vehicle System Dynamics* 36.4-5, S. 307–328. DOI: 10.1076/vesd.36.4.307.3547.
- U.S. GOVERNMENT (2020). *40 CFR § 86.1803–01 Definitions*. URL: <https://www.govinfo.gov/content/pkg/CFR-2009-title40-vol19/pdf/CFR-2009-title40-vol19-sec86-1803-01.pdf> (besucht am 29.08.2020).
- UDRIVE (2020). *Udrive Car Sharing*. URL: <https://www.udrive.ae> (besucht am 17.04.2020).
- UNSW SYDNEY (2020). *Australian Naturalistic Driving Study* /. URL: <http://www.ands.unsw.edu.au/> (besucht am 17.04.2020).
- UNTERREINER, Michael (2014). „Modellbildung und Simulation von Fahrzeugmodellen unterschiedlicher Komplexität“. Diss. Duisburg, Deutschland: Universität Duisburg-Essen.
- VAN NES, Nicole, BACKER-GRØNDAHL, Agathe, EENINK, Rob (2010). „Exploring Application Areas for Naturalistic Driving Observation Studies: Potential for Research on ITS“. In: *Proceedings of European Conference on Human Centred Design for Intelligent*

- Transport Systems*. Hrsg. von Josef KREMS, Tibor PETZOLDT, Matthias HENNING. Bd. 2. Berlin, Deutschland: HUMANIST publications, S. 333–343. ISBN: 978-2-9531712-1-1.
- VAN SCHAGEN, Ingrid, DE CRAEN, Saskia, VAN NES, Nicole, EENINK, Rob (2010). *The Areas of Interest of Potential Users for Naturalistic Observations Studies*. PROLOGUE Deliverable D1.2. Leidschendam, Niederlande: SWOV Institute for Road Safety Research.
- VAN SCHAGEN, Ingrid, WELSH, Ruth, BACKER-GRONDAHL, Agatha, HOEDEMAEKER, Marika, LOTAN, Tsippy, MORRIS, Andrew, SAGBERG, Fridulv, WINKELBAUER, Martin (2011). *Towards a Large Scale European Naturalistic Driving Study: Final Report of PROLOGUE*. PROLOGUE Deliverable D4.2. Leidschendam, Niederlande: SWOV Institute for Road Safety Research.
- VEREIN DEUTSCHER INGENIEURE (VDI) (2004). *2206: Entwicklungsmethodik für mechatronische Systeme*.
- VEREIN DEUTSCHER INGENIEURE (VDI) (2016). *4465: Blatt 1: Modellierung und Simulation - Modellbildungsprozess*.
- VICENTE, Bernardo A. Hernandez, JAMES, Sebastian S., ANDERSON, Sean R. (2020). „Linear System Identification Versus Physical Modeling of Lateral-Longitudinal Vehicle Dynamics“. In: *IEEE Transactions on Control Systems Technology*. DOI: 10.1109/TCST.2020.2994120.
- VIRGINIA TECH TRANSPORTATION INSTITUTE (2020). *Canada Naturalistic Driving Study Participant Portal*. URL: <https://www.canada-nds.net/> (besucht am 17. 04. 2020).
- VOSS, Leonard (2021). „Längsdynamik eines Plug-in-Hybriden, physikalische Modelle und künstliche neuronale Netze im Vergleich“. Abschlussarbeit. Duisburg, Deutschland: Universität Duisburg-Essen. DOI: 10.17185/duepublico/74034.
- WAND, Matt P., JONES, M. Chris (1995). *Kernel Smoothing*. New York, USA: Chapman & Hall. ISBN: ISBN 978-0-412-55270-0.
- WANG, Wenshuo, LIU, Chang, ZHAO, Ding (2017). „How Much Data Is Enough? A Statistical Approach with Case Study on Longitudinal Driving Behavior“. In: *IEEE Transactions on Intelligent Vehicles* 2.2, S. 85–98. DOI: 10.1109/TIV.2017.2720459.
- WILLUMEIT, Hans-Peter (1998). *Modelle und Modellierungsverfahren in der Fahrzeugdynamik*. Wiesbaden, Deutschland: Vieweg+Teubner Verlag. DOI: 10.1007/978-3-663-12247-0.

- YOUNG, Kristie et al. (2019). „What Are Australian Drivers Doing behind the Wheel? An Overview of Secondary Task Data from the Australian Naturalistic Driving Study“. In: *Journal of the Australasian College of Road Safety* 30.1, S. 27–33. DOI: 10.33492/JACRS-D-18-00085.
- ZIMMERMANN, Werner, SCHMIDGALL, Ralf (2014). *Bussysteme in der Fahrzeugtechnik*. 5. Aufl. ATZ/MTZ-Fachbuch. Wiesbaden, Deutschland: Springer Vieweg, Wiesbaden. DOI: 10.1007/978-3-658-02419-2.
- ZOMOTOR, Adam (1991). *Fahrwerktechnik: Fahrverhalten*. 2. Aufl. Würzburg, Deutschland: Vogel Communications Group GmbH & Co. KG. ISBN: 978-3-8023-0774-4.
- ZOMOTOR, Adam, BRAESS, Hans-Hermann, RÖNITZ, Rolf (1997). „Verfahren und Kriterien zur Bewertung des Fahrverhaltens von Personenkraftwagen : Ein Rückblick auf die letzten 20 Jahre. Teil 1“. In: *ATZ Automobiltech. Z* 99.12, S. 780–786. ISSN: 0001-2785.
- ZOMOTOR, Adam, BRAESS, Hans-Hermann, RÖNITZ, Rolf (1998). „Verfahren und Kriterien zur Bewertung des Fahrverhaltens von Personenkraftwagen: Ein Rückblick auf die letzten 20 Jahre. Teil 2“. In: *ATZ Automobiltech Z* 100.3, S. 236–243. DOI: 10.1007/BF03223403.

DuEPublico

Duisburg-Essen Publications online

UNIVERSITÄT
D U I S B U R G
E S S E N

Offen im Denken

ub | universitäts
bibliothek

Diese Dissertation wird via DuEPublico, dem Dokumenten- und Publikationsserver der Universität Duisburg-Essen, zur Verfügung gestellt und liegt auch als Print-Version vor.

DOI: 10.17185/duepublico/75503

URN: urn:nbn:de:hbz:465-20220406-114155-0

Alle Rechte vorbehalten.