Echtzeitfähige Schätzung dynamischer Zustände im Sattelzug

Online Estimation of Dynamic States in a Truck-Semitrailer

Von der Fakultät für Maschinenbau der Gottfried Wilhelm Leibniz Universität Hannover zur Erlangung des akademischen Grades Doktor-Ingenieur Dr.-Ing. genehmigte

Dissertation

von Zygimantas Ziaukas, M. Sc.

Referent: Prof. Dr.-Ing. Tobias Ortmaier
 Referent: Prof. Dr.-Ing. Eduard Reithmeier

Tag der Promotion: 15. Juni 2023

Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Mechatronische Systeme (imes) der Gottfried Wilhelm Leibniz Universität Hannover.

Zuerst möchte ich meinem Doktorvater Professor Tobias Ortmaier für die Möglichkeit zur Promotion und die Betreuung während der Bearbeitung danken. Ich habe mich stets sehr gut aufgehoben und von all den Ratschlägen, nicht nur bezüglich der Dissertation, inspiriert gefühlt. Das angenehme Arbeitsklima und das entgegengebrachte Vertrauen in der Zusammenarbeit bilden einen wesentlichen Grundstein für die erfolgreiche Arbeit am imes. Des Weiteren möchte ich Herrn Professor Reithmeier für die Übernahme des Korreferats und Herrn Professor Wurz für die Übernahme des Prüfungsvorsitzes danken.

Wesentliche Teile dieser Arbeit sind in Projekten mit BPW Bergische Achsen KG entstanden. An dieser Stelle möchte ich mich für die durchweg sehr angenehme Zusammenarbeit bedanken. Besonders hervorzuheben ist Dr.-Ing. Jan-Philipp Kobler, der die Kooperation mit dem imes initiiert und jederzeit engagiert mitgewirkt hat. Auch Simon Weßel möchte ich für die konstruktiven Diskussionen danken. Ein weiterer Dank gilt Eduard Penner, Willi Rempel und Frank Wolter aus dem Fahrversuch in Brüchermühle für ihren wichtigen Beitrag zu den experimentellen Untersuchungen - und die klugen Sprüche.

Weiterhin bedanke ich mich bei allen Kollegen für den fachlichen Austausch und die niemals langweilige Zeit am imes. Besonderer Dank gilt Kai Benjamin Eggers und Daniel Kaczor für die Einführung in den Acht-Achs-Prüfstand sowie Matthias Dagen, Mark Wielitzka und Alexander Busch für die hervorragende Leitung und den fachlichen Austausch. Den Kollegen in meiner Forschungsgruppe Identifikation & Regelung danke ich für das Feedback zu meiner Arbeit. Hervorzuheben ist Simon Ehlers, der durch die fachliche Nähe besonders intensiv daran und an zahlreichen Fachgesprächen beteiligt war.

Abschließend möchte ich meiner Familie und besonders meinen Eltern für die Möglichkeit des Studiums und die stetige Motivation für die Promotion danken. Ohne euch wäre das alles nicht möglich gewesen! Danke auch an alle Freunde, die mich besonders in schwierigen Phasen aufgemuntert haben. Ganz besonderer Dank gilt meiner Freundin Joanna. Jederzeit unterstützt du mich, munterst mich auf und bringst die nötige Geduld sowie das Verständnis für meine Taten mit.

Hannover, März 2023

Zygimantas Ziaukas

Kurzfassung

Moderne PKW sind umfangreich mit Sensorik sowie darauf basierenden Fahrassistenzsystemen ausgestattet und entwickeln sich stetig weiter hin zu autonomen Fahrzeugen. Eine ähnliche Situation ist bei der Zugmaschine von Sattelzügen zu vernehmen. Eine genauere Betrachtung des Sattelaufliegers offenbart, dass dieser lediglich in einem sehr geringen Maße mit elektronischen Komponenten ausgestattet ist. Dies hat zur Folge, dass aufgrund fehlender fahrdynamischer und sicherheitsrelevanter Informationen der Sattelauflieger sich potenziell zum Hindernis bei der Entwicklung autonom fahrender Sattelzüge entwickeln kann. Um dem vorzubeugen, werden in dieser Arbeit Ansätze erarbeitet, mit denen auf Grundlage von heute im Sattelauflieger serienmäßig verfügbarer Sensorik zusätzliche Informationen über fahrdynamische Zustände des Aufliegers generiert werden können.

Da die direkte messtechnische Erfassung einiger Zustände teilweise nur mit enormem technischen Aufwand realisierbar ist, kommen für diese häufig Schätzverfahren in Betracht. Grundsätzlich eignen sich zur Schätzung dynamischer Zustände verschiedene Methoden. In der Fahrzeugtechnik wurden in der Vergangenheit überwiegend modellbasierte Ansätze herangezogen. Diese haben zur Eigenschaft, dass sie physikalisch interpretierbar sind, erfordern gleichzeitig jedoch ein tiefgreifendes Systemverständnis. In der jüngeren Vergangenheit kommen vermehrt datenbasierte Methoden zum Einsatz, motiviert durch die erfolgreiche Anwendung in anderen Forschungsgebieten wie der Bildverarbeitung, der Signalverarbeitung und der Robotik. Datenbasierte Methoden sind in der Lage, komplexe Zusammenhänge auf Grundlage von Messdaten zu erlernen, ohne dass eine detaillierte physikalische Kenntnis über das zugrundeliegende System erforderlich wäre. Darunter leidet die Interpretierbarkeit des Lösungswegs. Im Fokus dieser Arbeit stehen die Analyse und der Vergleich von modell- und datenbasierten Methoden zur echtzeitfähigen Schätzung des Knickwinkels und der Reifenquerkräfte im Sattelauflieger. Die Ansätze bedienen sicher keiner über den Serienstandard hinausgehender Sensoren und erfordern keine Kommunikation zur Zugmaschine. Die gewählten Zielgrößen liefern erweiterte Kenntnisse über den dynamischen Fahrzustand sowie den Lasteintrag auf das Fahrwerk und dienen zur Überwachung des Verschleißzustands sicherheitsrelevanter Fahrwerkskomponenten. In einem ersten Schritt erfolgen die Untersuchungen in der Simulation. Dafür und für den modellbasierten Ansatz wird ein Sattelzugquerdynamikmodell entwickelt und in Anpassung an ein Versuchsfahrzeug parametriert. In einem zweiten Schritt werden die Erkenntnisse aus der Simulation auf das Versuchsfahrzeug übertragen und in experimentellen Versuchsfahrten auf einer Teststrecke sowie im öffentlichen Straßenverkehr validiert.

Schlagwörter: Nutzfahrzeugdynamik, Systemmodellierung, Parameteridentifikation, echtzeitfähige Zustandsschätzung, modellbasierte Zustandsschätzung, datenbasierte Zustandsschätzung

Abstract

Modern passenger cars are extensively equipped with sensors as well as driver assistance systems based on them and are constantly developing towards autonomous vehicles. A similar situation can be found in the truck unit of truck-semitrailer combinations. However, if the semitrailer is examined more closely, it can be seen that it is hardly equipped with electronic components. As a result, the semitrailer can potentially become an obstacle in the development of autonomously driving truck-semitrailer combinations due to missing dynamic and safety relevant information. In order to prevent this, in the present work approaches are being developed that can be used to generate additional information about the dynamic states of the semitrailer. These are solely based on sensors that are available as standard in a semitrailer today.

As the direct measurement of some states can only be realized with enormous technical effort, state estimation methods are often considered. In general, various methods are suitable for estimating dynamic states. In the past, model-based approaches were mainly used in vehicle technology. These have the property that they can be interpreted physically, but at the same time require a profound understanding of the system. More recently, data-based methods have been increasingly used, motivated by their successful application in other research areas such as image processing, signal processing, and robotics. Data-based methods are able to learn complex physical relationships based on measured data without requiring detailed knowledge of the underlying system. As an outcome, the interpretability of the approach suffers. The focus of this work is the analysis and comparison of model-based and data-based methods for real-time estimation of the hitch angle and the lateral tire forces in a semitrailer which supports condition monitoring of safety relevant chassis components. These do not require additional beyond serial sensors or communication to the truck. The chosen target variables provide extended knowledge about the dynamic state and the impact on the chassis. In a first step, the investigations are carried out in simulations. For this and for the model-based approach, a truck-semitrailer lateral dynamics model is developed and parameterized in adaptation to a test vehicle. In a second step, the findings from the simulation are transferred to the test vehicle and validated in experimental test drives on a test track as well as in public road traffic.

Keywords: commercial vehicle dynamics, system modelling, parameter estimation, real-time state estimation, model-based state estimation, data-based state estimation

Inhaltsverzeichnis

Vo	'orwort i		iii
Κι	Kurzfassung iv Abstract v		
At			
No	omenl	klatur	ix
1	Einl	eitung	1
	1.1	Stand des Wissens	4
		1.1.1 Modellbasierte Zustandsschätzung im Fahrzeug	5
		1.1.2 Datenbasierte Zustandsschätzung mit künstlichen neuronalen Netzen im	
		Fahrzeug	9
	1.2	Zielsetzung und Gliederung der Arbeit	11
2	Gru	ndlagen der modellbasierten Zustandsschätzung	15
	2.1	Allgemeiner Aufbau eines Beobachters	15
	2.2	Beobachtbarkeit	17
	2.3	Echtzeitfähige Beobachterstrukturen	19
		2.3.1 Erweitertes Kalman-Filter	20
		2.3.2 Unscented Kalman-Filter	21
	2.4	Beobachtung unbekannter Eingänge	23
	2.5	Auslegung und Einstellung echtzeitfähiger Beobachter	25
	2.6	Fazit	25
3	Gru	ndlagen der datenbasierten Zustandsschätzung mit künstlichen neuronalen	
	Netz	zen	27
	3.1	Nichtlineare autoregressive künstliche neuronale Netze mit externen Eingängen .	27
	3.2	Lernverfahren für künstliche neuronale Netze	30
	3.3	Datensatzaufbereitung	33
	3.4	Auslegung künstlicher neuronaler Netze	35
	3.5	Fazit	36

4	Mod	lellierung & Parametrierung der Sattelzugquerdynamik	39
	4.1	Modellierung der Sattelzugquerdynamik	40
		4.1.1 Koordinatensysteme	40
		4.1.2 Wahl der Modellierungstiefe der Sattelzugquerdynamik	40
		4.1.3 Modellierung des Reifen-Fahrbahn Kontakts	44
		4.1.4 Bewegungsgleichungen der Sattelzugquerdynamik	47
	4.2	Parametrierung	51
		4.2.1 Versuchsträger und Sensorik	51
		4.2.2 Parametrierungsablauf	54
	4.3	Experimentelle Validierung des Querdynamikmodells für den Sattelzug	60
	4.4	Fazit	63
5	Sim	ulative Untersuchungen zur Zustandsschätzung im Nutzfahrzeug	67
	5.1	Modellbasierte Zustandsschätzung in der Simulation	68
	5.2	Datenbasierte Zustandsschätzung in der Simulation	71
		5.2.1 Erstellung simulativer Trainingsdaten	71
		5.2.2 Netzauslegung und Training	72
	5.3	Ergebnisse der modellbasierten und datenbasierten Zustandsschätzung	75
	5.4	Robustheit der Methoden bezüglich ausgewählter Systemänderungen	78
		5.4.1 Variation des Prozessrauschens im Simulationsmodell	78
		5.4.2 Variation der Sattelaufliegermasse	81
		5.4.3 Variation des Massenschwerpunkts im Sattelauflieger	84
		5.4.4 Variation des Reibwerts	85
		5.4.5 Variation der Reifencharakteristik im Sattelauflieger	87
	5.5	Fazit	89
6	Ech	tzeitfähige Zustandsschätzung im Sattelzug	91
	6.1	Modellbasierte Zustandsschätzung	91
	6.2	Datenbasierte Zustandsschätzung	92
	6.3	Experimentelle Ergebnisse und Vergleich der Methoden	94
		6.3.1 Höherdynamische Manöver auf der Teststrecke	94
		6.3.2 Öffentlicher Straßenverkehr	95
		6.3.3 Analyse des Rechenaufwands	99
	6.4	Fazit	103
7	Zus	ammenfassung und Ausblick	105
	7.1	Zusammenfassung	106
	7.2	Ausblick	108
Lit	teratu	Irverzeichnis	109

Nomenklatur

Selten bzw. nur abschnittsweise verwendete Symbole und Formelzeichen sowie abweichende Bedeutungen werden ausschließlich im Text beschrieben.

Allgemeine Konventionen

Skalar	Kleinbuchstabe (kursiv): a
Vektor	Kleinbuchstabe (fett und kursiv): a
Matrix	Großbuchstabe (fett und kursiv): A

Lateinische Buchstaben

a	Abstand Schwerpunkt - Vorderachse bzw. Schwerpunkt - Königszapfen im Auflieger in ${ m m}$
$b^{\rm KNN}$	Biasterme des neuronalen Netzes
b	Abstand Schwerpunkt - Hinterachse(n) in m
B_s	Skalierungsfaktor innerhalb des Magic Formula Tire Modells
C_{lpha}	Schräglaufsteifigkeit in $N \operatorname{rad}^{-1}$
c_{λ}	Reifenkraftbeiwert der Reifenlängskräfte in N $\%^{-1}$
c_{1_s}, c_{2_s}	Skalierungsfaktoren innerhalb des Magic Formula Tire Modells
C_s	Skalierungsfaktor innerhalb des Magic Formula Tire Modells
C_{Train}	zu optimierendes Kostenfunktional des neuronalen Netzes
C_{Ident}	zu optimierendes Kostenfunktional der Parameteridentifikation
D_s	Skalierungsfaktor innerhalb des Magic Formula Tire Modells
E_s	Skalierungsfaktor innerhalb des Magic Formula Tire Modells
$f_{\rm Abt}$	Abtastfrequenz in Hz
F_x	Reifenlängskraft in N
F_y	Reifenquerkraft in N
F_z	Reifenaufstandskraft in N
g	Gravitationskonstante in $m s^{-2}$
h	Abstand Schwerpunkt - Königszapfen in der Zugmaschine in m
h^{KNN}	Ausgänge der Neuronenschichten des neuronalen Netzes
Н	Koppelkraft am Königszapfen in N
$i_{\rm Lenk}$	Lenkübersetzung
J	Gierträgheitsmoment in $\mathrm{kg}\mathrm{m}^2$

k	diskreter Zeitschritt
\Box_k	Größe bezieht sich auf den diskreten Zeitschritt k
$l_{ m R}$	Einlauflänge des Reifens in in m
$l_{ m Spur}$	Spurweite in m
$n_{ m FD}$	Anzahl der berücksichtigten Zeitschrittverzögerungen der Ausgangsrückführung
$n_{ m HL}$	Anzahl der versteckten Neuronenschichten
$n_{\rm HN}$	Anzahl der versteckten Neuronen pro versteckter Neuronenschicht
n_i	Anzahl Netzeingänge
$n_{ m ID}$	Anzahl der berücksichtigten Zeitschrittverzögerungen der Eingänge
n_{Ident}	Anzahl der verwendeten Messgrößen für die Parameteridentifikation
$n_{\rm iter,KNN}$	Anzahl der Trainingsiterationen des neuronalen Netzes
$n_{\rm iter,PSO}$	Anzahl der Iterationen der Partikelschwarmoptimierung
n_k	Anzahl der diskreten Zeitschritte
$n_{p,\mathrm{KNN}}$	Anzahl der Parameter des neuronalen Netztes
$n_{\rm Partikel}$	Anzahl der Partikel innerhalb der Partikelschwarmoptimierung
n_t	Anzahl der Netzausgänge
n_{Train}	Anzahl der verwendeten Manöver im Trainingsdatensatz
n_x	Anzahl der Systemzustände
n_y	Anzahl der Systemausgänge
\mathcal{N}	Normalverteilung
m	Fahrzeugmasse in kg
T	Schrittweite der zeitlichen Diskretisierung in s
v_x	Fahrzeuglängsgeschwindigkeit in $m s^{-1}$
v_y	Fahrzeugquergeschwindigkeit in $m s^{-1}$
$w^{(i,i+1)}$	Gewichte des neuronalen Netzes im Übergang zwischen Schicht i und $i + 1$
$w^{\mathrm{m}}, w^{\mathrm{c}}$	Gewichtungen der Sigma-Punkte im UKF
x, y, z	Fahrzeuglängsachse, -querachse, -hochachse
$x_{\rm SP_{RW}}$	Abstand Schwerpunkt - Rückwand des Sattelaufliegers in m
\boldsymbol{A}	Systemmatrix
B	Eingangsmatrix
C	Ausgangs- bzw. Messmatrix
D	Durchgangsmatrix
e	Fehler zwischen prädizierter und wahrer Zielgröße des neuronalen Netzes
$oldsymbol{E}$	Einheitsmatrix
H	Jacobi-Matrix der Ausgangsgleichungen $g()$ bzgl. des Zustands x
$oldsymbol{H}_{ ext{Hesse}}$	Hessematrix
i	Eingangsgrößen des neuronalen Netzes zu einem diskreten Zeitschritt
Ι	Eingangsgrößen des neuronalen Netzes über ein gesamtes Manöver

J	Jacobimatrix
K	Kalman-Verstärkung
0	Beobachtbarkeitsmatrix
p	Parametervektor des physikalischen Modells
$oldsymbol{p}_{\mathrm{Filt}}$	Parametervektor des physikalischen Modells innerhalb der Kalman-Filter
$p_{ m KNN}$	Parametervektor des neuronalen Netzes
$p_{ m Sim}$	Parametervektor des physikalischen Modells in der Simulation
$\hat{m{P}}, m{P}^-$	Fehlerkovarianz des Zustands: geschätzt, prädiziert
${old Q}$	Kovarianzmatrix des Prozessrauschens
R	Kovarianzmatrix des Messrauschens
S_A	Strukturmatrix zur Systemmatrix A
S_C	Strukturmatrix zur Ausgangsmatrix C
t	Zielgrößen bzw. Ausgänge des künstlichen neuronalen Netzes zu einem diskreten Zeitschritt
$oldsymbol{T},oldsymbol{T}^*$	vom neuronalen Netz über ein gesamtes Manöver prädizierte Zielgrößen, wahre Zielgrößen
\boldsymbol{u}	Eingangsvektor für Modelleingänge
v	stochastischer Prozesseinfluss
V	Jacobi-Matrix der Zustandsgleichungen $f()$ bzgl. des stochastischen Prozesseinflusses v
w	stochastischer Messeinfluss
W	Jacobi-Matrix der Ausgangsgleichungen $oldsymbol{g}()$ bzgl. des stochastischen Messeinflusses $oldsymbol{w}$
$oldsymbol{x}, \hat{oldsymbol{x}}, oldsymbol{x}^-$	Zustandsvektor, geschätzter Zustandsvektor, prädizierter Zustandsvektor
X	Satz von Sigma-Punkten
y	Ausgangsvektor bzw. Messvektor
${\cal Y}$	Satz von Ausgängen der Sigma-Punkte

Griechische Buchstaben

α	Schräglaufwinkel in rad
$\alpha_{\rm UKF}$	Parameter des UKF
β	Schwimmwinkel in rad
$\beta_{\rm UKF}$	Parameter des UKF
γ_1, γ_2	Parameter der Partikelschwarmoptimierung
δ	Lenkwinkel in rad
$\delta_{ m L}$	Lenkradwinkel in rad
η_1, η_2	Parameter der Partikelschwarmoptimierung
$\kappa_{ m UKF}$	Parameter des UKF
κ	Wankwinkel um die Längsachse x des Fahrzeugs in rad
$\lambda_{ m UKF}$	Parameter des UKF
λ	Längsschlupf in %
$\mu_{ m LM}$	Skalierungsfaktor für die Schrittweite innerhalb des Levenberg-Marquardt Algorithmus

- φ Nickwinkel um die Querachse y des Fahrzeugs in rad
- $\psi, \dot{\psi}$ Gierwinkel, Gierrate: Drehung um die Hochachse z des Fahrzeugs in rad bzw. rad s^{-1}
- $\sigma()$ Aktivierungsfunktion der Neuronen
- θ Knickwinkel in rad

Abkürzungen

ABS	Antiblockiersystem
ACC	Adaptive Cruise Control
CAN	controller area network
EBS	elektronisches Bremssystem
EKF	extended (dt.: erweitertes) Kalman-Filter
ESP	elektronisches Stabilitätsprogramm
FAS	Fahrassistenzsysteme
FEM	finite Elemente Methode
FFNN	feedforward neural network (dt.: vorwärts gerichtetes neuronales Netz)
KF	Kalman-Filter
KNN	künstliches neuronales Netz
LKW	Lastkraftwagen
MFTM	magic formula tire model
NARX-NN	nonlinear autoregressive neural network with exogeneous inputs
	(dt.: nichtlineares autoregressives KNN mit externen Eingängen)
NFZ	Nutzfahrzeug
NRMSE	normalized root mean square error (dt. Wurzel der mittleren Fehlerquadratsumme)
PKW	Personenkraftwagen
PSO	Partikelschwarmoptimierung
UKF	unscented Kalman-Filter

1 Einleitung

Durch die Entwicklung und den Einsatz moderner Transporttechnologien und die Liberalisierung des Welthandels erreicht die Globalisierung im Jahr 2022 einen fortgeschrittenen Zustand. Wenngleich der grenzüberschreitende Warenhandel weltweit seit den 1960er Jahren, bis auf die Jahre der Weltwirtschaftskrise um 2008 und die Corona Pandemie um 2020, durchweg zunimmt [Wor21], ist die zukünftige Entwicklung nicht eindeutig abzusehen. Einerseits beeinträchtigen aufkommende Handelskonflikte den internationalen Warenverkehr und ökologische Aspekte rücken verstärkt in den Vordergrund, was unter anderem die regionale Produktion von Gütern wieder attraktiver erscheinen lässt. Andererseits bestehen weltweit starke wirtschaftliche und technologische Abhängigkeiten zwischen den Ländern und Unternehmen, die z.T. weiter zunehmen und sich nicht ohne weiteres auflösen lassen. Diese und weitere Aspekte beeinflussen die bisherige Entwicklung und könnten potenziell zu einer Trendwende der Globalisierung führen, die ebenfalls einen Einfluss auf den Güterverkehr hätte.

Für eine globalisierte Weltwirtschaft ist der ständige Transport von Gütern unabdingbar. Bei genauerer Betrachtung des aktuellen Güterverkehrs in Europa ist festzustellen, dass über die Europäische Union hinweg der Warenverkehr zu ungefähr 75 % auf der Straße stattfindet. Deutschland ordnet sich mit einem marginal niedrigerem Anteil des Warenverkehrs auf der Straße im Mittelfeld ein [Sta21]. Ein Blick auf die Entwicklung des Anteils von Lastkraftwagen (LKW) an der Transportleistung im Güterverkehr in Deutschland zeigt einen leichten Anstieg über das vergangenen Jahrzehnt hinweg. In der Prognose für 2024 wird eine weitere Zunahme vorhergesagt [INT21]. Unter verschiedenen LKW-Arten wird häufig das Sattelkraftfahrzeug eingesetzt, welches auch als Sattelzug bezeichnet wird und in Bild 1.1(a) dargestellt ist. Es setzt sich typischerweise aus einer Zugmaschine und einem Sattelauflieger zusammen. In Deutschland steigt die Zahl zugelassener Sattelauflieger über das vergangenen Jahrzehnt stetig an, wie in Bild 1.1(b) zu erkennen ist, und erreicht im Jahr 2020 eine Anzahl von ca. 365.000 registrierter Sattelauflieger [Kra21]. Obwohl der Sattelzug als Fahrzeugverbund eine Einheit darstellt, sind die beiden Teilsysteme in technischer Hinsicht von Grund auf verschieden und erfordern eine separate Betrachtung.

Die Zugmaschine ist die aktive Einheit des Gespanns. Durch die Fahrzeugführerin bzw. den Fahrzeugführer wird das Fahrzeug über Gaspedal und Bremse entsprechend beschleunigt respektive verzögert. Über das Lenkrad wird die Führung des Fahrzeugs in lateraler Richtung realisiert. Die Zugmaschine hat in der Regel ein relativ konstantes Gesamtgewicht von ungefähr 8 t. Darüber hinaus besitzt die moderne Zugmaschine eine vergleichbare Anzahl an Sensoren und Recheneinheiten wie moderne PKW sowie eine Vielzahl diverser Fahrassistenzsysteme (FAS), beispielsweise ein Antiblockiersystem (ABS), ein elektronisches Stabilitätsprogramm (ESP) oder ein Abstandsregel-



(b) Entwicklung der zugelassenen Sattelauflieger in Deutschland [Kra21]

Bild 1.1: Schaubild und Kennzahlen zu Sattelaufliegern und deren Einsatz

tempomat (ACC). Dementsprechend sind die Anschaffungskosten im Vergleich zum Sattelauflieger signifikant höher. Im üblichen Einsatz werden Zugmaschine und Sattelauflieger beliebig variiert und kombiniert. Es gilt der Grundsatz, dass jeder Sattelauflieger von einer beliebigen Zugmaschine bewegt werden können muss. Dies garantiert eine genormte mechanische Verbindung über den sogenannten Königszapfen des Aufliegers, welcher in die Sattelkupplung der Zugmaschine eingeführt wird, sowie eine genormte elektronische Kommunikation, welche in der ISO 11992 festgeschrieben ist [DIN19]. Im Gegensatz zur Zugmaschine verhält sich der Sattelauflieger fahrdynamisch eher passiv, ausgenommen von Bremseingriffen, und reagiert entsprechend der über den Königszapfen eingeleiteten Kräfte. Die Ausstattung mit elektronischen Komponenten fällt vergleichsweise gering aus. Durchschnittlich sind ein Steuergerät und weniger als 10 Sensoren, beispielsweise Raddrehzahl- oder Drucksensoren, verbaut. Bei genauerer Betrachtung erscheint dies paradox, denn der Sattelauflieger trägt die wesentliche Last. Je nach Zuladung variiert die Gesamtmasse des Teilfahrzeugs deutlich zwischen 4 und 32 t. Bei großer Zuladung, insbesondere wenn die Gesamtmasse des Aufliegers die der Zugmaschine überschreitet, beeinflusst die Dynamik des Sattelaufliegers maßgeblich die Gesamtdynamik das Sattelzugs. Kommt es zur fahrdynamischen Instabilität des Gesamtsystems, kann dies fatale Folgen für die Sicherheit der Fahrzeuginsassen und anderer Verkehrsteilnehmer:innen haben. Unter diesen Aspekten drängt sich die Notwendigkeit von intelligenten Systemen im Sattelauflieger zur Steigerung der Fahrsicherheit auf. Die Möglichkeiten

mit der heutzutage serienmäßig vorhandenen Sensorik und Aktorik halten sich jedoch in Grenzen. Flächendeckend im Einsatz ist entsprechend lediglich ein elektronisches Bremssystem (EBS).

Die zuvor beschriebene Ausgangslage deutet darauf hin, dass der Sattelauflieger im aktuellen Zustand hemmend auf die Entwicklung von FAS und des autonomen Fahrens von Sattelzügen wirkt. Um weitere intelligente Systeme entwickeln zu können, sind zusätzliche Informationen über dynamische Fahrzeugzustände oder Systemparameter erforderlich. Darüber hinaus wird die automatisierte Erfassung fahrdynamischer Zustände und Parameter mit zunehmender Automatisierung von Nutzfahrzeugen und der damit einhergehenden Verringerung der Aufgaben der Fahrerin bzw. des Fahrers als Regler innerhalb des Regelkreises zur Fortbewegung des LKWs zunehmend relevanter. Aufgrund des enormen Kostendrucks der Branche steht eine direkte Messung dieser Größen im Zielkonflikt zwischen Informationsgewinn und minimalem Kostenaufwand. Als alternative Lösung bieten sich Schätzalgorithmen an, die mit Hilfe der vorhandenen Seriensensoren relevante Zielgrößen wie ausgewählte Fahrzeugzustände oder Parameter bestimmen. In diesem Zusammenhang wird auch von virtuellen Sensoren oder Softsensoren gesprochen. Aufgrund der zuvor beschriebenen häufig auftretenden Wechsel der Sattelauflieger an der Zugmaschine, sind grundsätzlich eigenständige Algorithmen innerhalb des Sattelaufliegers erstrebenswert. Diese sollten unabhängig von der Zugmaschine und von über den Serienstandard hinaus gehendem Informationsaustausch zwischen den Teilsystemen agieren.



(a) Der Knickwinkel θ



(b) Die Reifenquerkräfte im Sattelauflieger [BPW21]

Bild 1.2: In der vorliegenden Arbeit betrachtete Vertreter relevanter Zielgrößen der Zustandsschätzung im Sattelzug

Zwei in der vorliegenden Arbeit betrachtete Vertreter relevanter Zielgrößen innerhalb der Sattelzugquerdynamik sind der Knickwinkel θ zwischen Zugmaschine und Sattelauflieger, vgl. Bild 1.2(a), und die Reifenquerkräfte $F_{y_{ij}}$ des Sattelaufliegers, welche besonders bei engen Kurvenfahrten große Werte an der ersten und dritten Achse des Sattelaufliegers annehmen und sich sogar optisch durch eine deutliche Verformung des Reifens bemerkbar machen, vgl. Bild 1.2(b). Der Knickwinkel ist deshalb relevant, weil er Aufschluss über den aktuellen Fahrzustand des Sattelzugs gibt. Bei nicht autonomen Sattelzügen wird der Knickwinkel durch die Fahrerin bzw. den Fahrer über die Seitenspiegel überwacht und über Lenkeingriffe geregelt. Für den autonomen Sattelzug wird eine automatisierte Erfassung erforderlich, wobei eine direkte Messung kostenintensiv und aufgrund häufiger Ein- und Auskuppelvorgänge sowie der rauen Umgebung (bspw. große Kräfte und Schmiermittel am Königszapfen) impraktikabel ist. Die Reifenquerkräfte beschreiben die Interaktion mit der Fahrbahn und sind eine Ursache für Reifenverschleiß und Lasteinträge ins Fahrwerk. Somit lassen sich durch Kenntnisse dieser Rückschlüsse auf den Verschleiß und die Schädigung verschiedener Komponenten, wie beispielsweise der Lagern oder der Luftfeder, ziehen. Dabei ist der Reifenverschleiß nicht nur aus fahrzeugtechnischer Sicht, sondern auch aus ökologischen Aspekten interessant. Beispielsweise wäre über den Reifenverschleiß eine Quantifizierung der daraus resultierenden Emission von Kleinstpartikeln denkbar.

In den folgenden Abschnitten wird der aktuelle Stand des Wissens zur Zustandsschätzung im Nutzfahrzeug unter Berücksichtigung der Vorarbeiten im Bereich der PKW dargestellt und die Zielsetzung der Arbeit darin eingeordnet sowie die Gliederung der Arbeit vorgestellt.

1.1 Stand des Wissens

Die Schätzung dynamischer Zustände in Fahrzeugen hat eine jahrzehntelange Entwicklungsgeschichte vorzuweisen. Die ersten Ansätze sind auf die 1980er Jahre zurückzuführen [Kie88]. Dabei werden zunächst überwiegend physikalisch motivierte, modellbasierte Ansätze verwendet. Das ist möglicherweise auf den Vorteil der dadurch ermöglichten physikalisch Interpretierbarkeit und auf die in der Vergangenheit recht hohen Kosten für Datenspeicherung und deren Verarbeitung, welche im Rahmen von datenbasierten Ansätzen vermehrt erforderlich sind, zurückzuführen. Das zugrundeliegende Fahrzeugmodell kann dabei unterschiedlicher Art sein. In der Fahrzeugdynamik haben sich weitestgehend so genannte Grey-Box Modelle etabliert [Ise92]. Diese zeichnen sich durch das Heranziehen bekannter, physikalischer Gesetze bei der Modellbildung aus, wobei die unbekannten Parameter durch Identifikationsverfahren mit Hilfe experimenteller Messdaten bestimmt werden. Die physikalischen Modelle ermöglichen in der weiteren Entwicklung zunehmend fundierte Erkenntnisse der Systemtheorie zu generieren. Diese erlauben ein Urteil über Systemeigenschaften wie die Stabilität, das dynamische Verhalten oder die Robustheit, beispielsweise bezüglich Parameterschwankungen oder Störgrößen.

Gegenüber den modellbasierten Ansätzen werden auch rein datenbasierte Ansätze verfolgt. Im Bereich der Zustandsschätzung in der Fahrzeugdynamik dominieren künstliche neuronale Netze (KNN) das Forschungsumfeld [JYC19]. Ungeachtet der frühen Entwicklung und theoretischen Betrachtung [MWP43] von KNN werden diese erst in jüngerer Vergangenheit konkreter für die Zustandsschätzung in Fahrzeugen in Betracht gezogen. Dies ist durch die enorme Steigerung verfügbarer Daten mit den damit einhergehenden sinkenden Kosten für Rechenleistung und Speicherkapazität sowie in den durchbrechenden Erfolg in anderen Forschungsbereichen wie der Bildund Signalverarbeitung zu begründen. KNN sind in der Lage einen Zusammenhang zwischen ausgewählten Eingangs- und Zielgrößen auf Basis eines zugrundeliegenden Datensatzes abzubilden, erlauben jedoch nicht zwangsläufig eine Interpretierbarkeit der abgebildeten Zusammenhänge. Im Sprachgebrauch der Modellbildung könnte dieser Zusammenhang als Black-Box Modell bezeichnet werden. Es ist jedoch wichtig hervorzuheben, dass bei den modellbasierten Schätzansätzen unter Modell die approximative Abbildung der Systemdynamik verstanden wird, welche die Grundlage zur Zustandsschätzung ausmacht (beispielsweise im Prädiktionsschritt eines Beobachters), während bei den datenbasierten Ansätzen das angelernte Black-Box Modell direkt zum resultierenden Beobachter führt, welcher direkt verwendet werden kann.

Im Folgenden wird zunächst auf die bisherigen Erkenntnisse der modellbasierten Zustandsschätzung in Fahrzeugen eingegangen. Anschließend wird ein Überblick zur datenbasierten Zustandsschätzung in Form von KNN in Fahrzeugen vermittelt. Beide Unterkapitel greifen zuerst den Stand des Wissen in Bezug auf Personenkraftwagen (PKW) auf, die üblicherweise der Entwicklung im Nutzfahrzeug (NFZ) aufgrund geringerer Hürden bei der experimentellen Erprobung, eines größeren Marktvolumens und einer höheren Zahlungsbereitschaft der Kunden voraus sind, jedoch methodisch eine große Ähnlichkeit zu Nutzfahrzeugen aufweisen. Daraufhin folgt der Stand des Wissens bezogen auf die Zustandsschätzung in Nutzfahrzeugen, welcher von besonderer Relevanz hinsichtlich der vorliegenden Arbeit ist.

An dieser Stelle sei darauf hingewiesen, dass der Fokus innerhalb der variantenreichen Klasse der Nutzfahrzeuge auf einem klassischen Sattelzug nach Bild 1.1(a) liegt, welcher nach seinen Abmaßen konform mit der EU-Richtlinie 96/53/EG ist. Dieser besteht aus einer Zugmaschine mit 2 Achsen und einem Sattelauflieger mit 3 Achsen. Des Weiteren liegt der Schwerpunkt des Stands des Wissens auf Vorarbeiten mit Bezug zu den Zielgrößen dieser Arbeit - dem Knickwinkel und den lateralen Reifenquerkräften.

1.1.1 Modellbasierte Zustandsschätzung im Fahrzeug

Personenkraftwagen

Die modellbasierte Schätzung dynamischer Zustände im PKW ist umfangreich erforscht, ein Überblick zu aktuellen, veröffentlichten Forschungsarbeiten wird in [SAT19] und [JYC19] vermittelt. Dabei werden zahlreiche Zielgrößen adressiert, die wiederum in der Regel die Gemeinsamkeit aufweisen, dass sie relevant für die Fahrsicherheit und den Fahrkomfort sind. Beispielsweise sind das

- die Reifenkräfte, die zwischen Reifen und Fahrbahn auftreten,
- die laterale Geschwindigkeit des Schwerpunkts,
- die vertikale Geschwindigkeit des Schwerpunktes,
- der Schwimmwinkel, welcher den Winkel zwischen Fahrzeuglängsachse und der Richtung des Geschwindigkeitsvektors im Schwerpunkt darstellt und

 der Wankwinkel sowie die Wankrate, welche die Drehung um die Fahrzeuglängsachse beschreiben.

Ein Literaturüberblick speziell zur Schwimmwinkelschätzung ist [CLG18] zu entnehmen. Die folgenden Ausführungen beschränken sich besonders im Hinblick auf die Relevanz für die Inhalte dieser Arbeit auf die Schätzung der Reifenquerkräfte.



Bild 1.3: Exemplarische Darstellung unterschiedlicher Modellierungstiefen in der Fahrzeugdynamik

Für die modellbasierte Schätzung und Simulation der Reifenquerkräfte kommen unterschiedliche Modellierungstiefen zum Einsatz. Im Wesentlichen lassen sich dabei Einspur- und Zweispurmodelle, in Bild 1.3 dargestellt, unterscheiden, die zusätzlich über eine Abbildung der Wankdynamik verfügen können. Der entscheidende Unterschied liegt darin, dass im Zweispurmodell spurselektive Informationen über die Reifenkräfte gewonnen werden können, wohingegen beim Einspurmodell die einzelnen Spuren vereinfachend zusammengefasst werden. In diesen Modellen sind Teilmodelle für die Abbildung der auftretenden Reifenkräfte enthalten. Die Reifenmodelle sind von besonderer Bedeutung für das Gesamtmodell, da über die Reifen die Interaktion mit Fahrbahn erfolgt und die Reifenkräfte maßgeblich die Bewegung des Fahrzeuges beeinflussen. In der Realität ist das Verhalten der Reifenkräfte hochkomplex und nichtlinear [MW14]. In der Modellierung wird dieses Verhalten in unterschiedlichen Graden abstrahiert. Die Abstraktionsgrade reichen von statischen linearen Modellen mit einem Parameter bis hin zu nichtlinearen Modellen mit mehreren Parametern und unter Einbeziehung der Dynamik des Reifenkraftaufbaus. Eine Übersicht zu den verwendeten Reifenmodellen ist [JYC19] zu entnehmen, Grundlagen zur Modellierung der Reifendynamik werden in [PB92], [MW14], [BR15] beschrieben. Die Wahl der Modellierungstiefe ist von verschiedenen Faktoren abhängig, welche z.T. konträr zueinander sind, und muss für den speziellen Anwendungsfall sorgfältig getroffen werden. Komplexere Modelle können potenziell präzisere

Ergebnisse liefern, sind in der Regel jedoch schwieriger zu parametrieren und rechenaufwändiger. Ausführliche Informationen zur Modellierung der Fahrzeugdynamik sind beispielsweise in [MW14], [BR15] zu finden.

Bezogen auf die verwendeten Methoden zur Schätzung ist eine klare Dominanz des Kalman-Filters (KF) [Kal60] und seiner Derivate, darunter besonders das Extended Kalman-Filter (EKF) [FB66] und das Unscented Kalman-Filter (UKF) [JU97], zu erkennen [Ada14], [SAT19], [JYC19]. Auf die genaue Funktionsweise selbiger Derivate wird im späteren Verlauf der Arbeit eingegangen (s. Abschnitt 2.3). Darüber hinaus kommen seltener auch Luenberger-Beobachter [Lue64] und Sliding-Mode-Beobachter [DU95] zum Einsatz. Beide Methoden sind deterministisch und im Gegensatz zum Kalman-Filter nicht in der Lage, stochastische Informationen bezüglich der Prozessund Messunsicherheit zu berücksichtigen. Die Performanz modellbasierter Methoden zur Schätzung der Reifenquerkräfte, und auch im Allgemeinen zur Zustandsschätzung, ist von der Genauigkeit der zugrundeliegenden Modelle abhängig. Dabei ist unter anderem auch die Parametrierung von großer Bedeutung. Problematisch sind vor allem variierende Parameter wie z.B. die Fahrzeugmasse und deren Schwerpunkt, welche sich mit der Beladung und der Passagierzahl verändern können, sowie der Reibwert zwischen Fahrbahn und Reifen, der sich witterungsbedingt und durch die Beschaffenheit der Straße fortlaufend verändert. Dem wird durch die online Parameterschätzung begegnet, wie sie beispielsweise in [FKS08] für die Fahrzeugmasse und in [Wie20] für den Reibwert beschrieben wird.

Nicht nur die in dieser Arbeit besonders hervorgehobenen Sattelzüge werden mit einem Anhänger betrieben, auch im Bereich der PKW kommen Anhänger zum Einsatz. Durch den relativ geringen Anteil dieser Kombination am gesamten Verkehrsaufkommen von PKW findet sie nur wenig Beachtung in der Forschung. Wie für den Sattelzug ist der Zustand des Knickwinkels von Bedeutung für potenzielle Assistenzsysteme. Einige Patente beschreiben die Bestimmung des Knickwinkels. Diese basieren häufig auf Kameradaten [PJW⁺14], [RET14] oder zusätzlich zur Kamera auf Radar- und Ultraschallsensoren [LK09] des Zugfahrzeuges. Eine Schätzung des Knickwinkels aus Bewegungssensorik ist dem Autor lediglich aus [XTP⁺17] bekannt, wobei hier die Kommunikation zwischen Zugfahrzeug und Anhänger vorausgesetzt wird. Eine Schätzung der Reifenquerkräfte des Anhängers im Bereich der PKW ist nach Kenntnis des Autors nur in [HHK⁺22] beschrieben. Darin stützt sich die Schätzung allerdings auf Messgrößen des Zugfahrzeugs.

Nutzfahrzeuge

Im Bereich der Nutzfahrzeuge ist die Publikationsanzahl zur Zustandsschätzung deutlich geringer. Das ist unter den anderen zuvor genannten Gründen darauf zurückzuführen, dass der Kostendruck der Logistikbranche zu Einsparungen bezüglich der Ausstattung mit Sensorik und Recheneinheiten führt. In der Folge ist das Potenzial für den Einsatz von echtzeitfähigen Zustandsschätzern und Reglern im Serienfahrzeug sehr gering, was den Anhänger deutlich stärker betrifft als das Zugfahrzeug. Methodisch zeigt die Literatur ähnlich zum PKW-Bereich eine Dominanz der KF, aber auch in Nutzfahrzeugen werden Sliding-Mode- oder Luenberger-Beobachter verwendet. Einige Arbeiten beziehen sich lediglich auf die Zugmaschine ohne Anhänger. Die Autoren aus [IBM⁺14] beschreiben die Schätzung des Wankwinkels und der vertikalen Reifenkräfte bei gleichzeitiger Schätzung der Schwerpunkthöhe mittels Sliding Mode Beobachter. Die Ergebnisse werden experimentell validiert. In [DLT20] wird der Schwimmwinkel durch ein EKF geschätzt. Das verwendete Modell ist ein Einspurmodel mit einem nichtlinearen Reifenmodell, welches eine vereinfachte Alternative zum Reifenmodell nach Pacejka [PB92] darstellt. Zusätzlich werden die Reifenparameter online mitgeschätzt, um eine Alterung oder ein sich auf Grund von Umweltbedingungen änderndes Verhalten der Reifen zu berücksichtigen. Experimentelle Ergebnisse bestätigen den publizierten Ansatz.

Innerhalb des gesamten Sattelzugs zeigen [MC15] ebenfalls einen Ansatz zur Schwimmwinkelschätzung mit einem EKF, allerdings lediglich für die Zugmaschine. Das verwendete Modell ist ein lineares Einspurmodell und die Messgrößen umfassen Größen aus Zugmaschine sowie Sattelauflieger. Die Schätzung wird zusätzlich auf Untergrund mit niedrigem Reibwert untersucht, allerdings erfolgen die Untersuchungen rein simulativ. Experimentelle Ergebnisse zur Schwimmwinkel- und Wankwinkelschätzung für Zugmaschine und Sattelauflieger liefern [CC11]. Dazu wird ein duales EKF eingesetzt, welches aus zwei parallelen EKF besteht, wovon eins für die Paramterschätzung und eins für die Zustandsschätzung zuständig ist. Das verwendete Fahrdynamikmodell weist eine große Ähnlichkeit zu dem in [MC15] auf. Verwendete Messsignale sind die Lenkwinkel (der Sattelauflieger hat eine gelenkte Achse), die Längsgeschwindigkeit sowie die Gier- und Wankrate beider Teilfahrzeuge. Eine weitere Anwendung des EKF zur Schätzung der lateralen Geschwindigkeit und der Gierrate der Zugmaschine wird in [AG19] präsentiert. Es wird ein nichtlineares Zweispurmodell in Kombination mit einem linearen Reifenmodell verwendet. Unter den Messgrößen befinden sich der Knickwinkel und die Knickwinkelrate. Die Validierung erfolgt ausschließlich simulativ.

Wie auch im PKW bestehen einige Vorarbeiten zur Schätzung der Reifenkräfte im NFZ. So werden in [ID08] die vertikalen Reifenkräfte und in [KID⁺10] die lateralen und longitudinalen Reifenkräfte geschätzt. In beiden Fällen erfolgt die Validierung der Methoden ausschließlich simulativ und es kommt ein Sliding Mode Beobachter zum Einsatz. Außerdem benötigen beide Ansätzen Messsignale aus beiden Teilfahrzeugen.

Die Knickwinkelschätzung in einem Sattelzug ist dem Autor nur aus zwei Publikationen bekannt. In [CFS⁺10] wird der Knickwinkel auf Basis der Gierrate und des Lenkwinkels der Zugmaschine geschätzt. Es kommt ein Luenberger-Beobachter mit einem linearen Einspurmodell zum Einsatz. Das gewählte Reifenmodell ist stückweise linear, welches jedoch ab einem bestimmten Schräglaufwinkel in eine Sättigung der entstehenden Reifenquerkraft läuft. Zusätzlich finden Untersuchung zu verschiedenen Reibwerten zwischen Reifen und Fahrbahn statt. Die Validierung erfolgt anhand eines Simulationsmodells höherer Komplexität als das Modell des Beobachters. In [Alb13] wird der einer Serienanwendung wohl am nächsten kommende Ansatz formuliert, da die fehlende Kommunikation zur Zugmaschine berücksichtigt wird. Auf Basis der Längsgeschwindigkeit und der Gierrate im Sattelauflieger werden der Knickwinkel und der Lenkwinkel der Zugmaschine geschätzt. Die Schätzung erfolgt über ein KF basierend auf einem linearen Modell, welches eine Reihe von vereinfachender Annahmen mit sich bringt. Dazu gehört unter anderem die Annahme kleiner Lenk- und Knickwinkel. Dennoch werden erfolgreiche experimentelle Ergebnisse für Lenk- und Knickwinkel von über 40° in der Validierung erzielt.

Zusammenfassend zeigt der Stand des Wissens mit Bezug auf die modellbasierte Zustandsschätzung im Fahrzeug eine umfangreiche Erforschung im Bereich der PKW, während Nutzfahrzeuge in der Betrachtung nur geringe Aufmerksamkeit erlangen. Insbesondere die Schätzung von dynamischen Zuständen des Sattelaufliegers unter Bedingungen, wie sie im Serienfahrzeug vorzufinden sind, findet nahezu keine Beachtung.

1.1.2 Datenbasierte Zustandsschätzung mit künstlichen neuronalen Netzen im Fahrzeug

Im Gegensatz zur modellbasierten Zustandsschätzung befindet sich die datenbasierte Zustandsschätzung mit KNN für die Anwendung im Fahrzeug noch in der Anfangsphase. Wie bereits zuvor erwähnt, steigt das Interesse in jüngster Vergangenheit [SAT19] mit zunehmender Verfügbarkeit von Daten, getrieben durch sinkende Kosten für Rechenleistung und Speicherkapazitäten. Auch durch den Erfolg in anderen Forschungsbereichen, wie in der Bildverarbeitung oder der Robotik, drängt sich die Frage auf, inwiefern sich dieser auch im Fahrzeugbereich zur Zustandsschätzung verzeichnen lässt.

Personenkraftwagen

Eine Übersicht zur datenbasierten Zustandsschätzung im PKW wird in [JYC19] bereitgestellt. Dieser zufolge sind neben anderen datengetriebenen Ansätzen KNN besonders populär, um eine Schätzung dynamischer Fahrzeugzustände zu realisieren. Bisher untersuchte Zielgrößen decken sich im weitesten Sinne mit denen der modellbasierten Zustandsschätzung. Auffällig ist die große Anzahl an Studien zur Schwimmwinkelschätzung. Ein gesonderter Überblick zur datenbasierten Schwimmwinkelschätzung ist [CLG18] zu entnehmen. Im Folgenden wird sich wie im Abschnitt zuvor auf die Reifenkraftschätzung beschränkt.

Datenbasierte Ansätze eignen sich besonders für die Simulation und Schätzung der Reifenkräfte. Wie bereits erwähnt ist der Zusammenhang zwischen Schräglaufwinkel bzw. Schlupf und den daraus resultierenden Reifenkräften hoch komplex und nichtlinear [MW14]. Eine physikalische Modellierung erfordert tiefgreifendes Verständnis der auftretenden Effekte und kann ab bestimmter, geforderter Genauigkeit besonders im Hinblick auf eine echtzeitfähige Anwendung an ihre Grenzen kommen. Datenbasierte Ansätze drängen sich mit ihrer Fähigkeit, komplexe Zusammenhänge bei verhältnismäßig niedrigem Rechenaufwand abzubilden, für diese Anwendung auf [LK18]. Dennoch ist die Anzahl der Publikation recht überschaubar. Mögliche Gründe sind die hohen Kosten für die experimentelle Datenaufnahme durch die Notwendigkeit aufwändiger Prüfstände

oder kostspielige Reifenkraftsensoren, die vermehrt in der Industrie zur Verfügung stehen und nicht veröffentlicht werden. Außerdem bestehen bislang kaum Erfahrungen zu datengetriebenen Methoden im Hinblick auf eine mögliche Serienanwendung.

Zur direkten Schätzung der Reifenkräfte mittels datenbasierter Methoden und fahrzeuginterner Sensorik sind dem Autor keine Publikationen bekannt. Einige Arbeiten befassen sich mit der Abbildung der Reifenkräfte durch datenbasierte Ansätze, um diese in übergeordnete Strukturen, wie Fahrdynamikmodelle oder modellbasierte Zustandsschätzer, zu integrieren. In [BBG+09] wird ein KNN mit einer versteckten Schicht und einer Kombination aus Gauß-Kernelfunktionen und linearen Aktivierungsfunktionen antrainiert, um den Zusammenhang zwischen Aufstandskraft sowie Schräglaufwinkel bzw. Schlupf auf der einen Seite und resultierenden Reifenkräften auf der anderen Seite abzubilden. Die experimentelle Validierung weist den Erfolg der Methode nach. Dabei offenbart der Vergleich zwischen gemessen und durch das KNN simulierten Reifenkräften eine gute Übereinstimmung auf, die der physikalischen Simulation mittels etablierter Modelle signifikant überlegen ist. Für den Einsatz innerhalb einer Mehrkörpersimulation wird in [DL16] ein feedforward neural network (FFNN, engl. für vorwärts gerichtetes neuronales Netz) mit 13 Neuronen und einer versteckten Schicht zur Abbildung der lateralen Reifenkräfte angelernt. Die Eingangsgrößen sind Schräglaufwinkel, Sturz, Aufstandskraft und Reifendruck, die für den Trainingsdatensatz über einen definierten Bereich variiert werden. Auch hier wird die Eignung der Methode durch gute Übereinstimmung der simulierten Größen mit den Messdaten bestätigt. In ähnlicher Form kommt ein FFNN mit 10 Neuronen in der versteckten Schicht in [AK18] zum Einsatz. Die Abbildung der Reifenkräfte auf Basis des Schräglaufwinkels und der Längsbeschleunigung durch das KNN gliedert sich in ein physikalisches Fahrzeugmodell ein, welches in einem EKF zur Schätzung von Schwerpunktgeschwindigkeit und Gierrate verwendet wird. Die Validierung erfolgt rein simulativ. Über die genannten Arbeiten hinaus werden Ansätze unter zusätzlichem Einsatz von Sensorik im Reifen verfolgt, wie beispielsweise in [BXA⁺21]. Aufgrund der geringen Marktdurchdringung mit Sensorik ausgestatteter Reifen im Sattelauflieger werden diese Ansätze in dieser Arbeit nicht weiter betrachtet.

Nutzfahrzeuge

Im Bereich der Nutzfahrzeuge fällt die Publikationsanzahl bezüglich der datenbasierten Zustandsschätzung mit KNN deutlich kleiner aus. In [SRL⁺11] wird ein KNN zur Schätzung des Wankwinkels, der Querbeschleunigung und der Aufstandskräfte für einen Sattelzug präsentiert, um darauf aufbauend einen Regler für die Wankbewegung zu realisieren. Die Validierung wird simulativ durchgeführt. Ein Ansatz zur Schätzung des Knickwinkels unter Einsatz von Kamera und Lidar (engl. Abkürzung für *light detection and ranging*) am Zugfahrzeug zur Detektion des Anhängers wird in [Arn18] beschrieben. Auch hier erfolgen alle Untersuchungen rein simulativ. Neben der Zustandsschätzung wird in [TWH19] eine Parameterschätzung der Straßenneigung und der Fahrzeugmasse vorgestellt. Zur datenbasierten Schätzung der in dieser Arbeit genauer beleuchteten Zustände Knickwinkel und Reifenquerkräfte sind keine Vorarbeiten bekannt.

Aus dem Stand des Wissens zur datenbasierten Zustandsschätzung mit KNN lässt sich der Schluss ziehen, dass diese in Grundzügen Anwendung im PKW für unterschiedliche Zielgrößen finden, jedoch noch weitreichendes Forschungspotenzial aufweisen. Bezogen auf NFZ und speziell Sattelzüge besteht ein klares Defizit an Untersuchungen, welches in Teilen durch die vorliegende Arbeit verringert werden soll. Häufig fehlt es an experimenteller Validierung der vorgestellten Ansätze und es findet kein Vergleich zu den modellbasierten Ansätzen statt. Außerdem wird kaum auf das konkrete Vorgehen bei der Auslegung der datenbasierten Methoden eingegangen.

1.2 Zielsetzung und Gliederung der Arbeit

Der vorherige Abschnitt beschreibt den aktuellen Stand der Forschungsergebnisse im Bezug auf die modellbasierte und datenbasierte Zustandsschätzung im Fahrzeug. Daraus ist zu entnehmen, dass während die modellbasierte Zustandsschätzung im PKW umfangreich erforscht wird, dem gegenüber Nutzfahrzeugen, insbesondere Sattelzügen, bisher nur geringe Aufmerksamkeit gewidmet wird. Darüber hinaus werden in den bestehenden Arbeiten nur selten die besonderen Bedingungen innerhalb des Sattelzuges, wie der weitestgehend fehlende Informationsaustausch zwischen Zugfahrzeug und Sattelauflieger oder die geringe Anzahl verfügbarer Seriensensoren, berücksichtigt. Bezogen auf die datenbasierte Zustandsschätzung in Nutzfahrzeugen, insbesondere mit den Zielgrößen Reifenkräfte und Knickwinkel, ist keine Vorarbeit bekannt.

Ziel dieser Arbeit ist folglich die Schmälerung der zuvor aufgedeckten Forschungslücke. Dafür wird ein handelsüblicher Sattelzug in Betracht gezogen. Die Näherung an die Thematik der Zustandsschätzung erfolgt aus der Perspektive des Sattelaufliegers. Die Motivation dahinter ist zum einen, dass sich, wie in der Einleitung erwähnt, der Sattelauflieger besonders im beladenen Zustand maßgeblich auf die Dynamik des Gesamtzugs auswirkt. Zum anderen finden sich in der Praxis unzählige, fortlaufend wechselnde Kombinationsmöglichkeiten zwischen Zugmaschinen und Sattelaufliegern, was eigenständige Implementierungen zur Zustandsschätzung im Auflieger favorisiert.

Die konkreten Zielgrößen, welche genauer beleuchtet werden, sind der Knickwinkel und die lateralen Reifenkräfte. Im Rahmen der modellbasierten Zustandsschätzung kommen Derivate des KF zum Einsatz. Dabei wird eine zusätzliche Eingangsschätzung des Lenkwinkels notwendig, was im weiteren Verlauf genauer beschrieben wird. Darüber hinaus werden für die Schätzung ebendieser Zielgrößen KNN aus dem Bereich der datenbasierten Zustandsschätzung antrainiert. Die entstehenden modellbasierten und datenbasierten Methoden werden anschließend hinsichtlich Robustheit, Recheneffizienz und Entwicklungsaufwand verglichen. Dies erfolgt in einem ersten Schritt anhand von Simulationen, woraufhin im zweiten Schritt experimentelle Versuchsfahrten

mit einem realen Versuchsfahrzeug folgen. Um abschließend einen potenziellen Serieneinsatz zu ermöglichen, wird durchweg die Echtzeitfähigkeit der Anwendungen mitberücksichtigt.

Die vorliegende Arbeit gliedert sich wie folgt: In den Kapiteln 2 und 3 werden zunächst weitestgehend losgelöst vom Anwendungsfall der vorliegenden Arbeit die allgemeinen Grundlagen für die verwendeten Methoden erläutert. Dabei befasst sich Kapitel 2 mit den modellbasierten Methoden. Abschnitt 2.1 beginnt mit dem allgemeinen Aufbau modellbasierter Beobachter. Das für die Zustandsschätzung notwendige Kriterium der Beobachtbarkeit für nichtlineare Systeme wird in Abschnitt 2.2 thematisiert. In Abschnitt 2.3 werden zwei ausgewählte Vertreter echtzeitfähiger Beobachterstrukturen detailliert vorgestellt, namentlich das EKF und das UKF. Für den Fall, dass am zugrundeliegenden System unbekannte Eingangsgrößen anliegen, wird eine Berücksichtigung dieser Problematik erforderlich. Eine Möglichkeit dafür ist die simultane Eingangsschätzung, welche in Abschnitt 2.4 erläutert wird. Das Kapitel schließt mit der Auslegung und Einstellung der vorgestellten Beobachterstrukturen.

Kapitel 3 beschreibt KNN in ihren Grundzügen als Vertreter der datenbasierten Ansätze zur Zustandsschätzung. Dabei wird in Abschnitt 3.1 konkret auf den grundlegenden Aufbau nichtlinearer autoregressiver KNN mit externen Eingängen (NARX-KNN) eingegangen. Die Lernverfahren zur Anpassung der datenbasierten Methode an einen Anwendungsfall werden in Abschnitt 3.2 beschrieben. Die Aufbereitung des für den Lernvorgang erforderlichen Datensatzes folgt in Abschnitt 3.3. Abschnitt 3.4 schließt das Kapitel mit der konkreten Auslegung des zuvor allgemein beschriebenen KNN.

In Kapitel 4 wird die Herleitung des physikalischen Modells der Sattelaufliegerquerdynamik, welches für die nachfolgenden Untersuchungen in der Simulation sowie innerhalb der modellbasierten Ansätze verwendet wird, detailliert beleuchtet. Eingangs werden in Abschnitt 4.1 die verwendeten Koordinatensysteme festgelegt. Darauf folgt, unter Einbeziehung des Stands der Forschung, die Begründung zur Wahl der Modellierungstiefe, welche auf ein nichtlineares Einspurmodell mit einem nichtlinearen Reifenmodell fällt. Anschließend wird das resultierende Sattelzugquerdynamikmodell beschrieben. Die Parametrierung des Querdynamikmodells bezüglich des ebenfalls dort vorgestellten Versuchsträgers erfolgt in Abschnitt 4.2. Dabei gilt es zur Parameteridentifikation ein nichtlineares globales Optimierungsproblem anzugehen. Das Kapitel schließt mit der experimentellen Validierung des entstandenen Querdynamikmodells in Abschnitt 4.3.

Im fortlaufenden Kapitel 5 erfolgt die Untersuchung der zuvor beschriebenen Methoden in der Simulation anhand des ebenfalls zuvor hergeleiteten physikalischen Querdynamikmodells. Die Vorzüge der simulativen Untersuchung bestehen darin, dass jegliche Einflussfaktoren, Parameter sowie die wahren Werte der Zielgrößen exakt bekannt sind. In Abschnitt 5.1 wird die Anwendung der modellbasierten Zustandsschätzung auf das Simulationsmodell unter idealen Bedingungen erläutert, in Abschnitt 5.2 folgt selbiges für den datenbasierten Ansatz. Die Ergebnisse werden in Abschnitt 5.3 dargestellt und verglichen. Da die in der Simulation zunächst ideal vorliegenden Bedingungen nicht realistisch sind, werden in Abschnitt 5.4 ausgewählte Abweichungen davon

separiert betrachtet, um eine Abschätzung des Einflusses dieser Abweichungen auf die Güte der verschiedenen Schätzmethoden abzuleiten.

In Kapitel 6 folgt die Übertragung der Erkenntnisse aus der Simulation auf das reale Versuchsfahrzeug. Das Vorgehen zur Anwendung der Methoden in den Abschnitten 6.1 und 6.2 ist weitestgehend analog zu Kapitel 5. Die experimentelle Validierung und der Vergleich anhand von Manövern auf einer Teststrecke und im öffentlichen Straßenverkehr erfolgt in Abschnitt 6.3, wobei zusätzlich ein Augenmerk auf die Echtzeitausführung gelegt wird.

Kapitel 7 fasst die vorgestellten Methoden und Erkenntnisse in einer abschließenden Diskussion zusammen. Darüber hinaus werden Empfehlungen für mögliche weiterführende Forschungsansätze gegeben.

2 Grundlagen der modellbasierten Zustandsschätzung

Zur Regelung und Überwachung von Systemen oder Prozessen ist eine genaue Kenntnis der aktuellen Systemzustände in Echtzeit notwendig. Um diese zu erlangen, kann eine direkte Messung der notwendigen Zustandsgrößen erfolgen. Das ist jedoch aus diversen Gründen nicht immer möglich. Einerseits ist möglicherweise die Erfassung eines bestimmten Zustands in Echtzeit durch einen Sensor schlicht nicht realisierbar, wie es z.B. im Falle eines Biogasreaktors für den Zustand der Biomassenverteilung gilt, die ausschließlich unter Zuhilfenahme eines Labors bestimmt werden kann [Lun14]. Andererseits kann die Messung eines erforderlichen Zustandes aus Kostengründen nicht in der Endanwendung erfolgen. So ist beispielsweise in Fahrzeugen die Messung des Schwimmwinkels wirtschaftlich nicht darstellbar, dennoch liefert dieser wichtige Informationen über die dynamische Fahrsituation, was das im Abschnitt 1.1 beschriebene Forschungsinteresse begründet. Im Nutzfahrzeug, speziell dem Sattelauflieger, fallen unter diese Kategorie die Zustände Knickwinkel und Reifenquerkräfte.

Eine Möglichkeit nicht gemessene Zustände echtzeitfähig zu bestimmen liefern modellbasierte Beobachter, welche in diesem Kapitel vorgestellt werden. Dabei werden zunächst im Abschnitt 2.1 der allgemeine Aufbau und die Systembeschreibung eingeführt. Es wird zunächst die Annahme getroffen, das Modell des Systems sei gegeben. Eine Grundvoraussetzung für die Realisierung von Beobachtern ist die Beobachtbarkeit. Die Prüfung der Beobachtbarkeit für nichtlineare Systeme wird im Abschnitt 2.2 thematisiert. Anschließend werden im Abschnitt 2.3 konkrete, echtzeitfähige Beobachterstrukturen aus der Gruppe der KF vorgestellt. Für den Fall, dass nicht alle Eingangsgrößen des Systems gemessen werden, ist darüber hinaus eine Schätzung der Systemeingänge notwendig. Die dafür erforderliche Erweiterung des Beobachters wird in Abschnitt 2.4 erläutert. Abschnitt 2.5 beschreibt die praktische Einstellung sowie Auslegung der Beobachter und benennt dabei aufkommende Probleme. Das Kapitel schließt mit einem kurzen Fazit.

2.1 Allgemeiner Aufbau eines Beobachters

Die allgemeine Struktur von Beobachtern ist Bild 2.1 zu entnehmen. Auf ein reales dynamisches System wirken in der Regel Eingangsgrößen, welche im Eingangsvektor $u \in \mathbb{R}^{n_u}$ zusammengefasst sind, die zu einer zeitlichen Veränderung innerhalb des Systems führen. Der aktuelle Zustand des Systems kann durch die Systemzustände im Zustandsvektor $x \in \mathbb{R}^{n_x}$ beschrieben werden. Die Eingangsgrößen bewirken demnach eine Änderung der Systemzustände. Um Informationen über den aktuellen Zustand des realen Systems zu erhalten und diese beispielsweise im Rahmen



Bild 2.1: Allgemeine Beobachterstruktur

einer Regelung zu verwenden, ist neben der Messungen der Eingangsgrößen die Erfassung von Messgrößen $y \in \mathbb{R}^{n_y}$, auch als Ausgangsgrößen bezeichnet, notwendig. Diese Messgrößen können einzelne Zustände oder nichtlineare Kombinationen dieser und der Eingänge sein und in unterschiedlicher Qualität und Aktualität vorliegen. Unterschreiten einer oder beide dieser Merkmale die erforderlichen Anforderungen, die je nach Anwendung unterschiedlich ausfallen können, oder können einige Zustände aus zuvor genannten Gründen nicht gemessen werden, bieten sich modellbasierte Beobachterstrukturen zur Schätzung der realen Zustände an.

Dem Entwurf modellbasierter Beobachter liegt ein Modell des betrachteten Systems zugrunde. Als Modell wird eine mathematische Beschreibung zur Approximation des Systemverhaltens verstanden und kann allgemein in Form einer nichtlinearen Zustandsraumdarstellung

$$\dot{\boldsymbol{x}}(t) = \boldsymbol{f}\left(\boldsymbol{x}(t), \boldsymbol{u}(t)\right) \tag{2.1}$$

$$\boldsymbol{y}(t) = \boldsymbol{g}\left(\boldsymbol{x}(t), \boldsymbol{u}(t)\right) \tag{2.2}$$

dargestellt werden [Ada14]. Die Gleichung (2.1) kann als Prozess- oder Systemgleichung bezeichnet werden, die Gleichung (2.2) als Mess- oder Ausgangsgleichung. Die Modellbildung kann auf unterschiedliche Art und Weise erfolgen und beispielsweise darin variieren, wie stark physikalische Gesetze oder Messdaten in den Prozess einbezogen werden. Weiterführende Informationen sind unter anderem [Nel20], [IM11] zu entnehmen. Durch das Modell werden zusätzlich zu den gemessenen Eingangs- und Messgrößen weitere Informationen über das Systemverhalten, wie z.B. die Zusammenhänge der gemessenen Größen mit den Systemzuständen und Parametern, generiert und im Rahmen eines Beobachteralgorithmus mit den Informationen aus den gemessenen Größen fusioniert. Diese Arbeit beschränkt sich auf die Beschreibung von KF als modellbasierte Beobachteralgorithmen, welche im Folgenden detailliert beschrieben werden. Weitere prominente Beispiele sind, wie schon erwähnt, der Luenberger [Lue64] und der Sliding Mode Beobachter [SHM87]. Deren Eignung scheint für den späteren Anwendungsfall weniger geeignet, da sie u.a. nicht in der Lage sind stochastische Informationen bezüglich der Prozess- und Messunsicherheit zu berücksichtigen.

2.2 Beobachtbarkeit

Eine systemtheoretische Voraussetzung für die Schätzung von Zuständen ist die Beobachtbarkeit. Ein System gilt im Allgemeinen als beobachtbar, wenn sich aus dem Verlauf der Eingangsgrößen u(t) und der Messgrößen y(t) der Anfangszustand x(0) und somit jedes x(t) eindeutig rekonstruieren lässt. Für nichtlineare Systeme lässt sich die Beobachtbarkeit nicht immer oder nur mit sehr großem Aufwand berechnen. In diesem Fall kann auf die schwache Beobachtbarkeit ausgewichen werden, welche die Beobachtbarkeit für eine bestimmte Umgebung um den betrachteten Arbeitspunkt einschränkt. Für Modelle mit einer großen Anzahl von Zuständen führt jedoch auch dieser Ansatz zu hoher Komplexität und Rechenaufwand. Eine ausführliche Beschreibung der zuvor erwähnten Ansätze und deren Problematiken ist in [Ada14] zu finden.

Alternativ bietet sich zur Abschätzung der Beobachtbarkeit die Betrachtung des fortlaufend im Arbeitspunkt x_k und u_k linearisierten Systems

 A_k

$$\Delta \dot{\boldsymbol{x}}\Big|_{\boldsymbol{x}_{k},\boldsymbol{u}_{k}} \approx \underbrace{\frac{\partial \boldsymbol{f}\left(\boldsymbol{x},\boldsymbol{u}\right)}{\partial \boldsymbol{x}}\Big|_{\boldsymbol{x}_{k},\boldsymbol{u}_{k}}}_{\partial \boldsymbol{x}} \Delta \boldsymbol{x} + \underbrace{\frac{\partial \boldsymbol{f}\left(\boldsymbol{x},\boldsymbol{u}\right)}{\partial \boldsymbol{u}}\Big|_{\boldsymbol{x}_{k},\boldsymbol{u}_{k}}}_{\partial \boldsymbol{u}} \Delta \boldsymbol{u}, \qquad (2.3)$$

 \boldsymbol{B}_k

$$\Delta \boldsymbol{y}\Big|_{\boldsymbol{x}_{k},\boldsymbol{u}_{k}} \approx \underbrace{\frac{\partial \boldsymbol{g}\left(\boldsymbol{x},\boldsymbol{u}\right)}{\partial \boldsymbol{x}}\Big|_{\boldsymbol{x}_{k},\boldsymbol{u}_{k}}}_{\boldsymbol{C}_{k}} \Delta \boldsymbol{x} + \underbrace{\frac{\partial \boldsymbol{g}\left(\boldsymbol{x},\boldsymbol{u}\right)}{\partial \boldsymbol{u}}\Big|_{\boldsymbol{x}_{k},\boldsymbol{u}_{k}}}_{\boldsymbol{D}_{k}} \Delta \boldsymbol{u}$$
(2.4)

an [Wie20]. Die Beobachtbarkeit des linearisierten Systems kann mit Hilfe von verschiedenen Kriterien wie nach Kalman, Hautus, Gram oder Gilbert bestimmt werden [Lun14]. Im Folgenden wird lediglich das Beobachtbarkeitskriterium nach Kalman betrachtet, welches sich auf die Beobachtbarkeitsmatrix

$$\boldsymbol{O}_{k} = \begin{pmatrix} \boldsymbol{C}_{k} \\ \boldsymbol{C}_{k} \boldsymbol{A}_{k} \\ \boldsymbol{C}_{k} \boldsymbol{A}_{k}^{2} \\ \vdots \\ \boldsymbol{C}_{k} \boldsymbol{A}_{k}^{n-1} \end{pmatrix}$$
(2.5)

bezieht und besagt: Das linearisierte System ist vollständig beobachtbar, wenn die Beobachtbarkeitsmatrix O den Rang n_x hat, somit

$$\operatorname{Rang} \boldsymbol{O}_k = n_x \tag{2.6}$$

gilt. Im Gegensatz zu nichtlinearen Systemen ist für lineare Systeme die Beobachtbarkeit nicht vom Eingang u abhängig [Ada14]. Im Falle der Linearisierung im jeweiligen Arbeitspunkt wird diese Abhängigkeit durch Einsetzten der Eingangsgröße mit berücksichtigt. Die Aussage der Beobachtbarkeit lässt sich zumindest für den betrachteten Arbeitspunkt auf das nichtlineare System übertragen. In [Lun14] wird im Zusammenhang mit der praktischen Prüfung des Beobachtbarkeitskriteriums nach Kalman bei Systemen mit Parametern, welche sich um mehrere Größenordnungen unterscheiden, vor numerischen Problemen gewarnt. Einen numerisch stabileren Ansatz bietet die strukturelle Systemanalyse.

Bei der Prüfung auf strukturelle Beobachtbarkeit wird das zugrundeliegende System auf die für die Beobachtbarkeit erforderlichen Signalkopplungen innerhalb des Systems untersucht, ohne die tatsächlichen Parameterwerte zu betrachten. Fehlende Beobachtbarkeit ist häufig nicht durch die Systemparameter zu begründen, sondern durch fehlende Ausgangsverbundenheit von Zuständen. Die strukturelle Beobachtbarkeit ist somit ein notwendiges Kriterium für die Beobachtbarkeit, lässt jedoch keine allgemeine, gesicherte Schlussfolgerung über tatsächliche Beobachtbarkeit zu. Beispielsweise kann durch eine bestimmte Parametrierung des Modells innerhalb des Beobachters eine Paralleldynamik entstehen. Zur Bestimmung der strukturellen Beobachtbarkeit werden die numerische Systemmatrix A_k und die Ausgangsmatrix C_k (aus Gleichungen (2.3-2.4)) in ihre entsprechenden Strukturmatrizen S_{A_k} und S_{C_k} überführt. Dabei bleiben in den Matrizen Nullen unverändert stehen und die von Null verschiedenen Einträge werden durch Sterne ersetzt. Mit den Rechenregeln für Strukturmatrizen lässt sich folglich die strukturelle Beobachtbarkeit bestätigen, wenn

- 1. das System ausgangsverbunden ist, d.h. eine direkte oder indirekte Kopplung der Zustände zu den Messgrößen besteht, und
- 2. die Bedingung

struktureller Rang
$$\begin{pmatrix} \mathbf{S}_{\mathbf{A}_k} \\ \mathbf{S}_{\mathbf{C}_k} \end{pmatrix} = n_x$$
 (2.7)

erfüllt ist.

Das Vorhergegangene genauer beschreibende und weitere Details zur strukturellen Systemanalyse sind [Lun14] zu entnehmen.

Ist die Beobachtbarkeit des betrachteten Systems gegeben, können Beobachterstrukturen zur Zustandsschätzung eingesetzt werden. Im nachfolgenden Abschnitt werden ausgewählte Variationen des KFs vorgestellt.

2.3 Echtzeitfähige Beobachterstrukturen

Nachdem der allgemeine Aufbau und die systemtheoretischen Voraussetzung für Beobachter erläutert wurden, werden in diesem Abschnitt mit dem erweiterten Kalman-Filter (EKF) und dem Unscented Kalman-Filter (UKF) zwei ausgewählte Beobachterstrukturen im Detail vorgestellt. Diese wurden aufgrund ihrer Eignung zur Anwendung bei nichtlinearen Systemen gewählt. Wie bereits in Abschnitt 1.1.1 erwähnt, sind diese Vertreter des KFs darüber hinaus besonders häufig in Publikationen zur Zustandsschätzung im Fahrzeug vertreten und haben sich bezüglich ihrer Performanz hinsichtlich Genauigkeit und Echtzeitfähigkeit bewiesen (vgl. Abschnitt 1.1). Der wesentliche Unterschied zwischen den beiden Ansätzen besteht darin, dass das EKF auf einer Linearisierung des nichtlinearen Systems im jeweils aktuellen Arbeitspunkt beruht, während das UKF zusätzlich zum Arbeitspunkt einen Satz von benachbarten Stützstellen durch die nichtlineare, das System beschreibende Funktion transformiert, um anschließend einen gewichteten Mittelwert zu bilden. Ein anschaulicher Vergleich der beiden Methoden ist beispielsweise in [van04], [Wie20] und [Luc17] zu finden.

Für die Implementierung auf digitalen Recheneinheiten ist eine zeitdiskrete Systembeschreibung notwendig. Die Überführung des zeitkontinuierlichen Systems der Gleichungen (2.1)-(2.2) in eine zeitdiskrete Form kann mittels bekannter Diskretisierungsverfahren vorgenommen werden [DR08]. Ein simples, häufig verwendetes Verfahren ist die explizite Diskretisierung nach Euler. Es basiert auf der Approximation der Zeitableitung mittels Differenzenquotienten

$$\dot{\boldsymbol{x}}(t) = \boldsymbol{f}(\boldsymbol{x}(t), \boldsymbol{u}(t)) = \lim_{\epsilon \to 0} \frac{\boldsymbol{x}(t+\epsilon) - \boldsymbol{x}(t)}{\epsilon}$$

$$\approx \frac{\boldsymbol{x}(t+T) - \boldsymbol{x}(t)}{T}.$$
(2.8)

Durch Einführung eines Index $k \in \mathbb{N}$ wird eine übersichtlichere Schreibweise der Größen zu diskreten Zeitpunkten $t_k = kT$ bei einem festen Abtastintervall $T = \frac{1}{f_{Abt}}$, wobei f_{Abt} die Abtastfrequenz darstellt, ermöglicht. Somit gilt $\boldsymbol{x}_k = \boldsymbol{x}(t_k = kT)$ und Gleichung (2.8) lässt sich in die Form

$$\boldsymbol{x}_{k+1} = \boldsymbol{x}_k + T\boldsymbol{f}\left(\boldsymbol{x}_k, \boldsymbol{u}_k\right), \qquad \boldsymbol{x}_{k=0} = \boldsymbol{x}_0 \tag{2.9}$$

überführen. Die Anwendung des Diskretisierungsverfahrens und Verschiebung um einen Zeitschritt liefert die Ausgangsform der nachfolgenden Erläuterungen in zeitdiskreter, nichtlinearer Form

$$\boldsymbol{x}_{k} = \boldsymbol{f}_{d} \left(\boldsymbol{x}_{k-1}, \boldsymbol{u}_{k-1}, \boldsymbol{v}_{k-1} \right), \qquad (2.10)$$

$$\boldsymbol{y}_{k} = \boldsymbol{g}_{d} \left(\boldsymbol{x}_{k}, \boldsymbol{u}_{k}, \boldsymbol{w}_{k} \right), \qquad (2.11)$$

wobei zusätzlich stochastische Einflüsse innerhalb der Gleichungen durch v_k und w_k berücksichtigt werden. Es wird von mittelwertfreien, unkorrelierten Normalverteilungen für die stochastischen

Einflüsse $\mathbb{R}^{n_v} \ni v_k \sim \mathcal{N}(0, Q_k)$ mit der sogenannten Kovarianz des Prozessrauschens Q_k und $\mathbb{R}^{n_w} \ni w_k \sim \mathcal{N}(0, R_k)$ mit der sogenannten Kovarianz des Messrauschens R_k ausgegangen.

2.3.1 Erweitertes Kalman-Filter

Das 1960 von Rudolf E. Kalman eingeführte und nach ihm benannte Filter ermöglicht eine rekursive, echtzeitfähige Schätzung von Systemzuständen auf Basis von Messungen der Eingänge und Ausgänge eines Systems unter Einbeziehung eines Systemmodells. Es ist zunächst nur unter der Annahme linearer Systeme gültig und nur für diese als optimal bzgl. der Schätzung unter den gegebenen Bedingungen bzw. Informationen anzusehen [Kal60]. Aufgrund der Tatsache, dass viele reale Systeme jedoch nichtlinear sind, ist das originale KF nicht direkt für diese anwendbar. In der Folge wurde das EKF formuliert [FB66], welches sich auf eine Linearisierung des nichtlinearen Systems im aktuell prädizierten Systemzustand stützt. Eine Voraussetzung dafür ist die Differenzierbarkeit der Funktionen f_d und g_d .

Die algorithmische Abfolge zu jedem Zeitpunkt $k = 0, ..., k_{end}$ zwischen Beginn und Ende des Betrachtungszeitraums k_{end} gliedert sich in zwei Schritte. Zunächst wird ein Prädiktionsschritt

$$\boldsymbol{x}_{k}^{-} = \boldsymbol{f}_{d} \left(\hat{\boldsymbol{x}}_{k-1}, \boldsymbol{u}_{k-1}, \boldsymbol{0} \right),$$
 (2.12)

$$\boldsymbol{P}_{k}^{-} = \boldsymbol{A}_{k} \hat{\boldsymbol{P}}_{k-1} \boldsymbol{A}_{k}^{\mathrm{T}} + \boldsymbol{V}_{k} \boldsymbol{Q}_{k} \boldsymbol{V}_{k}^{\mathrm{T}}, \qquad (2.13)$$

mit
$$\boldsymbol{A}_{k} = \frac{\partial \boldsymbol{f}_{d}}{\partial \boldsymbol{x}_{k-1}} \Big|_{\hat{\boldsymbol{x}}_{k-1}, \boldsymbol{u}_{k-1}, \boldsymbol{0}}$$
 und $\boldsymbol{V}_{k} = \frac{\partial \boldsymbol{f}_{d}}{\partial \boldsymbol{v}_{k-1}} \Big|_{\hat{\boldsymbol{x}}_{k-1}, \boldsymbol{u}_{k-1}, \boldsymbol{0}}$,

durchgeführt. Dabei ist x_k^- der prädizierte Zustand und P_k^- die prädizierte Varianz des Schätzfehlers für den prädizierten Zustand, A_k die Jacobi-Matrix der Funktion f_d bezüglich des Zustands x im Arbeitspunkt ($\hat{x}_{k-1}, u_{k-1}, 0$), während V_k die Jacobi-Matrix der Funktion f_d bezüglich des stochastischen Einflusses v_k im selbigen Arbeitspunkt darstellt. Im Prädiktionsschritt wird somit basierend auf der vorhergegangenen Schätzung \hat{x}_{k-1} und dem dazugehörigen Eingang ausschließlich mit dem Modellwissen ein Schritt voraus prädiziert, wobei das Prozessrauschen v_{k-1} zu Null gesetzt wird. Zum Zeitpunkt der Initialisierung k = 1 des Filters wird eine initiale Normalverteilung des Anfangszustandes $\mathcal{N}(\hat{x}_0, \hat{P}_0)$ angenommen.

Der prädizierte Zustandsvektor wird mit Hilfe der Messung y_k im Korrekturschritt

$$\boldsymbol{K}_{k} = \boldsymbol{P}_{k}^{-} \boldsymbol{H}_{k}^{\mathrm{T}} \left(\boldsymbol{H}_{k} \boldsymbol{P}_{k}^{-} \boldsymbol{H}_{k}^{\mathrm{T}} + \boldsymbol{W}_{k} \boldsymbol{R}_{k} \boldsymbol{W}_{k}^{\mathrm{T}} \right)^{-1}, \qquad (2.14)$$

mit
$$\boldsymbol{H}_{k} = \frac{\partial \boldsymbol{g}_{d}}{\partial \boldsymbol{x}_{k}} \Big|_{\boldsymbol{x}_{k}^{-}, \boldsymbol{u}_{k}, \boldsymbol{0}}$$
 und $\boldsymbol{W}_{k} = \frac{\partial \boldsymbol{g}_{d}}{\partial \boldsymbol{w}_{k}} \Big|_{\boldsymbol{x}_{k}^{-}, \boldsymbol{u}_{k}, \boldsymbol{0}},$

$$\boldsymbol{x}_{k} = \boldsymbol{x}_{k}^{-} + \boldsymbol{K}_{k} \left(\boldsymbol{y}_{k} - \boldsymbol{g}_{d} \left(\boldsymbol{x}_{k}^{-}, \boldsymbol{u}_{k}, \boldsymbol{0} \right) \right), \qquad (2.15)$$

$$\boldsymbol{P}_{k} = \left(\boldsymbol{E}_{n_{\boldsymbol{x}}} - \boldsymbol{K}_{k}\boldsymbol{H}_{k}\right)\boldsymbol{P}_{k}^{-}, \qquad (2.16)$$

berichtigt, mit der Kalman-Verstärkung K_k sowie der Jacobi-Matrix H_k der Funktion g_d bezüglich des Zustands x und der Jacobi-Matrix W_k der Funktion g_d bezüglich des stochastischen Einflusses w, beide im Arbeitspunkt $(x_k^-, u_k, 0)$. Die Matrix $E_{n_x} \in \mathbb{R}^{n_x \times n_x}$ steht für die Einheitsmatrix.

Unter der Annahme additiver stochastischer Einflüsse für die Gleichungen (2.10) und (2.11)

$$\boldsymbol{x}_{k} = \boldsymbol{f}_{d} \left(\boldsymbol{x}_{k-1}, \boldsymbol{u}_{k-1} \right) + \boldsymbol{v}_{k-1},$$
 (2.17)

$$\boldsymbol{y}_{k} = \boldsymbol{g}_{d}\left(\boldsymbol{x}_{k}, \boldsymbol{u}_{k}\right) + \boldsymbol{w}_{k}, \qquad (2.18)$$

vereinfachen sich die Jacobi-Matrizen $V_k = E$ in Gleichung (2.13) und $W_k = E$ in Gleichung (2.14) zu Einheitsmatrizen.

2.3.2 Unscented Kalman-Filter

Die Linearisierung des nichtlinearen Systems innerhalb des EKF-Algorithmus ist an die bereits genannte Voraussetzung differenzierbarer Systemgleichungen geknüpft und kann darüber hinaus zu verschiedenen Unzulänglichkeiten führen. Beispielsweise besteht bei hochgradig nichtlinearen Systemen die Gefahr, dass die Linearisierung in entsprechenden Arbeitspunkten zu signifikanten Abweichungen vom Verhalten des originalen Systems führt [Wie20].

Den Schwächen des EKF kann mit dem alternativen Ansatz des UKF [JU97] begegnet werden. Anstelle der Linearisierung wird neben dem aktuellen Arbeitspunkt ein Satz von Punkten in der Umgebung des Arbeitspunktes, zusammengefasst als Sigma-Punkte bezeichnet, durch die nichtlinearen Funktion transformiert und anschließend in einer gewichteten Summe zu einem Resultat zusammengeführt. Die Anzahl der Sigma-Punkte und deren Verteilung haben einen erheblichen Einfluss auf die Genauigkeit und den Rechenaufwand und können variiert werden. Im Folgenden wird der Ablauf des UKF detailliert erläutert. Die zugrundeliegenden Annahmen entsprechen denen des EKF und berücksichtigen von Beginn an die Annahme additiver Rauschterme [van04].

Zunächst wird ein Satz \mathcal{X} von $2n_x + 1$ Sigma-Punkten mit der aktuellen Kovarianzmatrix des Schätzfehlers \hat{P}_{k-1} unter Anwendung der Unscented Transformation [Jul02]

$$\begin{aligned}
\hat{\boldsymbol{\mathcal{X}}}_{k-1,0} &= \hat{\boldsymbol{x}}_{k-1} , \\
\hat{\boldsymbol{\mathcal{X}}}_{k-1,i} &= \hat{\boldsymbol{x}}_{k-1} + \left(\sqrt{(n_x + \lambda_{\text{UKF}}) \, \hat{\boldsymbol{P}}_{k-1}} \right)_i, & i = 1, \dots, n_x , \quad (2.19) \\
\hat{\boldsymbol{\mathcal{X}}}_{k-1,i} &= \hat{\boldsymbol{x}}_{k-1} - \left(\sqrt{(n_x + \lambda_{\text{UKF}}) \, \hat{\boldsymbol{P}}_{k-1}} \right)_{i-n_x}, & i = n_x + 1, \dots, 2n_x ,
\end{aligned}$$

definiert. Unter $(.)_i$ ist die Auswertung der *i*-ten Spalte des Ausdrucks zu verstehen. Über den Parameter

$$\lambda_{\rm UKF} = \alpha_{\rm UKF}^2 (n_x + \kappa_{\rm UKF}) - n_x \tag{2.20}$$

lässt sich die Verteilung der Sigma-Punkte um \hat{x}_{k-1} einstellen. Dabei beeinflusst α_{UKF} die Spreizung und κ_{UKF} dient zur Anpassung an statistische Momente höherer Ordnung [JU97]. Die Gewichte für die Zusammenführung der Sigma-Punkte nach der Transformation durch die nichtlinearen Funktionen berechnen sich zu

$$w_0^{\rm m} = \frac{\lambda_{\rm UKF}}{n_x + \lambda_{\rm UKF}},$$

$$w_0^{\rm c} = \frac{\lambda_{\rm UKF}}{n_x + \lambda_{\rm UKF}} + \left(1 - \alpha_{\rm UKF}^2 + \beta_{\rm UKF}\right),$$

$$w_i^{\rm m} = w_i^{\rm c} = \frac{1}{2\left(n_x + \lambda_{\rm UKF}\right)},$$

$$i = 1, \dots, 2n_x ,$$

$$(2.21)$$

wobei $w_i^{\rm m}$ die Gewichte der Sigma-Punkte und $w_i^{\rm c}$ die Gewichte der dazugehörigen Fehlerkovarianzen sind. Über $\beta_{\rm UKF}$ lässt sich Vorwissen über die Verteilung einbringen ($\beta_{\rm UKF} = 2$ für Normalverteilungen) [JU97].

Im Zeitablauf werden nun zu jedem Zeitschritt k im Prädiktionsschritt die Sigma-Punkte durch die Systemfunktion transformiert

$$\boldsymbol{\mathcal{X}}_{k,i}^{-} = \boldsymbol{f}_{\mathrm{d}}\left(\hat{\boldsymbol{\mathcal{X}}}_{k-1,i}, \boldsymbol{u}_{k-1}\right), \qquad (2.22)$$

und daraufhin gewichtet aufsummiert zur Prädiktion des Zustandes

$$\boldsymbol{x}_{k}^{-} = \sum_{i=0}^{2n_{x}} w_{i}^{\mathrm{m}} \boldsymbol{\mathcal{X}}_{k,i}^{-} , \qquad (2.23)$$

die prädizierte Fehlerkovarianzen ergibt sich aus

$$\boldsymbol{P}_{k}^{-} = \sum_{i=0}^{2n_{x}} w_{i}^{c} \left(\boldsymbol{\mathcal{X}}_{k,i}^{-} - \boldsymbol{x}_{k}^{-} \right) \left(\boldsymbol{\mathcal{X}}_{k,i}^{-} - \boldsymbol{x}_{k}^{-} \right)^{\mathrm{T}} + \boldsymbol{Q}_{k} \quad .$$
(2.24)

Im anschließenden Korrekturschritt wird die Prädiktion durch die aktuelle Messung y_k korrigiert. Dazu werden zunächst die transformierten Sigma-Punkte aus Gleichung (2.22) durch die Messgleichung

$$\boldsymbol{\mathcal{Y}}_{k,i}^{-} = \boldsymbol{g}_{\mathrm{d}} \left(\boldsymbol{\mathcal{X}}_{k,i}^{-}, \boldsymbol{u}_{k} \right) \tag{2.25}$$

erneut transformiert und anschließend gewichtet aufsummiert zur prädizierten Messung

$$\boldsymbol{y}_{k}^{-} = \sum_{i=0}^{2n_{x}} w_{i}^{\mathrm{m}} \boldsymbol{\mathcal{Y}}_{k,i}^{-}, \qquad (2.26)$$

die dazugehörige Kovarianz berechnet sich zu

$$\boldsymbol{P}_{yy,k}^{-} = \sum_{i=0}^{2n_{x}} w_{i}^{c} \left(\boldsymbol{\mathcal{Y}}_{k,i}^{-} - \boldsymbol{y}_{k}^{-} \right) \left(\boldsymbol{\mathcal{Y}}_{k,i}^{-} - \boldsymbol{y}_{k}^{-} \right)^{\mathrm{T}} + \boldsymbol{R}_{k} \,.$$
(2.27)

Für die eigentliche Korrektur ist zusätzlich die Kovarianz

$$\boldsymbol{P}_{xy,k}^{-} = \sum_{i=0}^{2n_x} w_i^{c} \left(\boldsymbol{\mathcal{X}}_{k,i}^{-} - \boldsymbol{x}_k^{-} \right) \left(\boldsymbol{\mathcal{Y}}_{k,i}^{-} - \boldsymbol{y}_k^{-} \right)^{\mathrm{T}}$$
(2.28)

notwendig, um die Kalman-Verstärkung

$$\boldsymbol{K}_{k} = \boldsymbol{P}_{xy,k}^{-} \left(\boldsymbol{P}_{yy,k}^{-} \right)^{-1}$$
(2.29)

zu bestimmen, welche in die Berechnung der aktuellen Schätzung und deren Fehlerkovarianz

$$\hat{\boldsymbol{x}}_{k} = \boldsymbol{x}_{k}^{-} + \boldsymbol{K}_{k} \left(\boldsymbol{y}_{k} - \boldsymbol{y}_{k}^{-} \right), \qquad (2.30)$$

$$\hat{\boldsymbol{P}}_{k} = \boldsymbol{P}_{k}^{-} - \boldsymbol{K}_{k} \boldsymbol{P}_{yy,k}^{-} \boldsymbol{K}_{k}^{\mathrm{T}}$$
(2.31)

eingeht. Somit sind die bekanntesten Vertreter der KF, namentlich das EKF und das UKF, in ihren Grundzügen beschrieben. Im folgenden Abschnitt wird zunächst auf den Umgang mit unbekannten Eingangsgrößen eingegangen, anschließend wird die praktische Auslegung der Filter beschrieben.

2.4 Beobachtung unbekannter Eingänge

Die in den vorhergegangenen Abschnitten in ihren Grundzügen beschriebenen Derivate des KFs gehen von der Annahme aus, dass neben den Messgrößen y auch alle Eingangsgrößen u des Systems laufend erfasst werden (vgl. Bild 2.1). Dies ist für reale Systeme, insbesondere im Serieneinsatz ohne experimentelle Zusatzsensorik, nicht immer der Fall. Gründe dafür können, ähnlich wie bei den zu schätzenden Zustandsgrößen, entweder die dafür zusätzlich aufkommenden und wirtschaftlich nicht abbildbaren Kosten sein oder die Erfassung dieser Größen ist im Serienbetrieb unpraktikabel oder schlichtweg nicht in Echtzeit möglich [Irl16]. Dieser Problematik kann durch das simultane Mitschätzen der unbekannten Eingangsgröße begegnet werden. In der englischsprachigen Fachliteratur wird dabei von *unknown input estimation* gesprochen.

Bei der Schätzung von Zuständen in Systemen mit unbekannten Eingängen ist grundsätzlich zwischen einem Beobachter bei unbekannten Eingängen und für unbekannte Eingänge zu unterscheiden [Irl16]. Im ersten Fall liegt die Zielsetzung darin, trotz der unbekanntem Eingang eine robuste und korrekte Schätzung der Zustände zu realisieren. Im zweiten Fall gilt es die unbekannten Eingänge mit zu rekonstruieren. Da es durchaus ein übergeordnetes Interesses an der unbekannten Eingangsgröße geben kann, wird für den im weiteren Verlauf der Arbeit thematisierten Anwendungsfall im Sattelzug der Fall inklusive Rekonstruktion weiter betrachtet.

Für die Zustandsschätzung mit Rekonstruktion der unbekannten Eingänge bestehen unterschiedliche Ansätze. Ähnlich wie bei der Parameterschätzung sind im Bereich der KF einerseits parallele Strukturen zur Schätzung der Eingänge neben der eigentlichen Zustandsschätzung publiziert worden, welche auch als dual KF bezeichnet werden. Andererseits bestehen Ansätze einer in die Zustandsschätzung integrierten Eingangschätzung, welche in der englischsprachigen Literatur als *joint* KF bezeichnet werden. Eine Übersicht inklusive experimenteller Validierung anhand eines ausgewählten Prüfstandes sowie Verweisen auf bestehende Literatur zu den einzelnen Ansätzen wird in [ACP+17] gegeben. Obwohl der parallele Schätzansatz in Bezug auf die resultierenden Genauigkeit dem integrierten Ansatz überlegen ist, wird der integrierte Ansatz aufgrund seines geringeren Rechenaufwands im Hinblick auf die Implementierung auf einer seriennahen Hardware innerhalb dieser Arbeit bevorzugt und im Folgenden genauer beschrieben [MC05].

Um eine integrierte Schätzung der unbekannten Eingänge zu ermöglichen, wird die Ausgangsform der Prozessgleichung (2.10) so angepasst, dass einerseits der Eingangsvektor in die bekannten u^{b} und unbekannten u^{u} Eingangsgrößen aufgeteilt wird und der Zustandsvektor um die unbekannten Eingangsgrößen zu einem erweiterten Zustandsvektor

$$\boldsymbol{x}_{k}^{\mathrm{a}} = \begin{pmatrix} \boldsymbol{x}_{k} \\ \boldsymbol{u}_{k}^{\mathrm{u}} \end{pmatrix}$$
 (2.32)

ergänzt wird. Entsprechend resultieren die angepasste Prozess- und Messgleichung in

$$\boldsymbol{x}_{k}^{\mathrm{a}} = \begin{pmatrix} \boldsymbol{x}_{k} \\ \boldsymbol{u}_{k}^{\mathrm{u}} \end{pmatrix} = \begin{pmatrix} \boldsymbol{f}_{\mathrm{d}} \left(\boldsymbol{x}_{k-1}^{\mathrm{a}}, \boldsymbol{u}_{k-1}^{\mathrm{b}}, \boldsymbol{u}_{k-1}^{\mathrm{u}}, \boldsymbol{v}_{k-1} \right) \\ \boldsymbol{u}_{k-1}^{\mathrm{u}} + \boldsymbol{v}_{k-1}^{\boldsymbol{u}^{\mathrm{u}}} \end{pmatrix}, \qquad (2.33)$$

$$\boldsymbol{y}_{k} = \boldsymbol{g}_{d} \left(\boldsymbol{x}_{k}^{a}, \boldsymbol{u}_{k}^{b}, \boldsymbol{w}_{k} \right).$$
(2.34)

Dabei kann der additive Term $v_k^{u^u} \sim \mathcal{N}(0, Q_k^{u^u})$ nicht analog zu Gleichung (2.10) als Prozessrauschen aufgefasst werden. Vielmehr ermöglicht die als Pseudoprozessrauschen angenommene stochastische normalverteilte Variable eine dynamische Änderung des unbekannten Eingangs, welche mit der Größe der eingestellten Varianz skaliert. Die Validität der getroffenen Annahme bezüglich der Dynamik des Eingangs ist sicherlich in Frage zu stellen, allerdings besteht häufig keine bessere Alternative. Bei zusätzlicher Kenntnis über die Dynamik der zu schätzenden Eingänge kann diese grundsätzlich innerhalb der angepassten Prozessgleichung (2.33) eingebracht werden, was zu einer verbesserten Eingangsschätzung führen kann. Mit der in diesem Abschnitt beschriebenen Anpassung der Prozessgleichung kann entsprechend der in Abschnitt 2.3 beschriebenen Grundlagen eine Zustandsschätzung mit integrierter Eingangsschätzung erfolgen. Die praktische Auslegung der Beobachter ist Bestandteil des nachfolgenden Abschnitts.
2.5 Auslegung und Einstellung echtzeitfähiger Beobachter

Mit der Auslegung und Einstellung von KF sind diverse Herausforderungen verbunden. Beginnend mit der Modellierung des Systems ist auf einen Kompromiss zwischen Genauigkeit, die für die Zielanwendung notwendig ist, und Rechenaufwand, welcher auf der Zielhardware realisiert werden kann, zu achten. Beides geht konträr mit dem gewählten Rechentakt, der Komplexität der Systemfunktionen und der Dimension des Systems einher. Dabei ist der Rechentakt auch auf die Abtastrate der eingesetzten Sensorik für die Erfassung der Eingangs- und Messgrößen abzustimmen. Ist die Verwendung der Schätzgrößen in der Rückführung eines Regelkreises vorgesehen, ist darauf zu achten, dass die Fehlerdynamik des Beobachters deutlich größer als die Dynamik des geschlossenen Regelkreises ist [Lun14].

Die zuvor erwähnten Annahmen Gauß'schen Rauschens und deren Kenntnis bedingen die Optimalität der Filter hinsichtlich der Minimierung der Fehlerkovarianz. Die Überprüfung dieser Annahmen gestaltet sich teilweise jedoch schwierig. Während der Erwartungswert und die Kovarianz R des Messrauschen w in den meisten Fällen experimentell ermittelt werden kann, gibt es zur Bestimmung des Prozessrauschens v kein einheitliches Vorgehen und ist oft prinzipbedingt nicht möglich. Häufig wird das Prozessrauschen heuristisch innerhalb der KF eingestellt. Die Werte der Kovarianzmatrix des Prozessrauschens Q werden anhand von repräsentativen Testfällen so gewählt, dass ein gutes Schätzergebnis zustande kommt. Durch das Prozessrauschen wird somit einerseits die Dynamik des Filters eingestellt, andererseits kann darin die Ungenauigkeit der Modellierung berücksichtigt werden [WB95]:

- Verhältnismäßig großes Prozessrauschen Q bedeutet größeres Vertrauen in die Messung und eine höhere Dynamik des Filters,
- Verhältnismäßig kleineres Prozessrauschen Q bedeutet größeres Vertrauen in das Modell und eine geringere Dynamik des Filters.

Darüber hinaus beeinflusst die Initiierung der Fehlerkovarianz P_0 wie stark der initialen Schätzung vertraut wird und damit einhergehend das Einschwingverhalten des Beobachters. Neben dem heuristischen Ansatz können Optimierungsalgorithmen zur Filtereinstellung verwendet werden [JK09]. Darüber hinaus gibt es Ansätze der zustandsabhängigen Einstellung der Filter [ORR06], [RR07] und der online Anpassung der Kovarianzterme [RD016]. Beides bringt jedoch erhöhten Rechen- und Parametrierungsaufwand mit sich.

2.6 Fazit

In diesem Kapitel wurden in allgemeiner Form die Grundlagen der modellbasierten Zustandsschätzung vorgestellt. Aufbauend auf einem nichtlinearen Modell eines zugrundeliegenden Systems ist zunächst die Grundvoraussetzung der Beobachtbarkeit erörtert worden. Aus der großen Vielfalt möglicher Beobachterstrukturen wurden, motiviert durch den Stand des Wissen zur im weiteren Verlauf der Arbeit vorgestellten Anwendung im Nutzfahrzeug, das EKF und das UKF zur detaillierten Beschreibung ausgewählt. Dadurch sind die Gemeinsamkeiten und Unterschiede beider Ansätze nachvollziehbar dargestellt. Abschließend erfolgte eine Betrachtung der Auslegung und Einstellung der Filter.

Die nicht triviale Modellierung und Einstellung der Filter führt dazu, dass spezifisches Domänenwissen über das System und zu den Schätzmethoden notwendig ist. Je nach Systemkomplexität kann die Systemmodellierung mit erheblichem Entwicklungsaufwand verbunden sein oder der Zielkonflikt aus Genauigkeit und Recheneffizienz lässt sich nicht in befriedigendem Maße lösen. Einen alternativen Ansatz bieten datenbasierte Methoden der Zustandsschätzung, die im nachfolgenden Kapitel thematisiert werden.

3 Grundlagen der datenbasierten Zustandsschätzung mit künstlichen neuronalen Netzen

Neben den in Kapitel 2 vorgestellten modellbasierten Methoden zur Zustandsschätzung stellen datenbasierte Methoden einen alternativen Ansatz dar. Der wesentliche Unterschied besteht darin, dass Kenntnisse über den Zusammenhang zwischen den Eingangs- und den Schätzgrößen nicht auf Basis von bekannten Naturgesetzen und der Systemtheorie, sondern direkt aus experimentell erfassten Daten abgeleitet werden. Dies erfordert je nach Komplexität zum Teil erheblichen Rechenaufwand in der Entwicklungsphase, kann jedoch potenziell in der Endanwendung bei gleicher oder sogar höherer Genauigkeit recheneffizienter sein [LK18]. Die steigende Verfügbarkeit von Daten und die sinkenden Kosten für Rechenleistung machen die datenbasierte Alternative auch in anderen Forschungsbereichen wie der Bild- und Signalverarbeitung sukzessiv attraktiver. Unter den verschiedenen datenbasierten Methoden werden besonders KNN zur Zustandsschätzung im Fahrzeug verwendet [JYC19] und erfahren daher verstärkte Aufmerksamkeit in dieser Arbeit.

In diesem Kapitel wird die grundlegende Funktionsweise und der Entwurf von KNN mit Fokus auf die echtzeitfähige Zustandsschätzung anhand eines ausgewählten rekurrenten KNNs erläutert und dessen Auswahl begründet. Zunächst wird in Abschnitt 3.1 der allgemeine Aufbau und die Funktionsweise des rekurrenten KNNs beschrieben. Anschließend befasst sich Abschnitt 3.2 mit Verfahren, die zum Anlernen des zuvor vorgestellten Netztyps verwendet werden können. Für das erfolgreiche Anlernen von KNN ist ein repräsentativer Datensatz notwendig. Die Anforderungen an diesen sowie dessen Aufbereitung und Aufteilung wird in Abschnitt 3.3 thematisiert. Für den konkreten Anwendungsfall ist das zunächst allgemein beschriebene rekurrente KNN problem-spezifisch auszulegen. Wichtige Aspekte der Auslegung und mögliche Vorgehensweisen werden abschließend in Abschnitt 3.4 aufgezeigt.

3.1 Nichtlineare autoregressive künstliche neuronale Netze mit externen Eingängen

KNN können grundsätzlich in sehr unterschiedlichen Strukturen entworfen und eingesetzt werden. Sie unterscheiden sich im Wesentlich in der Anzahl der verwendeten Neuronen, deren Art und deren Anordnung sowie Vernetzung. Für die dynamische Zustandsschätzung auf Grundlage von Sensorsignalen eignet sich beispielsweise das nachfolgend vorgestellte und ausgewählte nichtlineare autoregressive KNN mit externen Eingängen (NARX-KNN), da es strukturell Parallelen zu den modellbasierten Methoden aufweist. Grundsätzlichen wären auch LSTM- (Long Short-Term

Memory) [HS97] oder GRU-KNN (Gated Recurrent Unit) [CvG⁺14] denkbar. Diese gelten als Weiterentwicklungen des NARX-KNN und es werden ihnen bessere Konvergenzeigenschaften besonders beim Training vielschichtiger Strukturen zugeschrieben, was zur optimierten Verwertung zeitlich weiter zurückliegender Informationen führt. Im Falle der iterativen Schätzung von Systemzuständen erscheint dies jedoch nicht als zwangsläufig erforderlich und wird im Rahmen der vorliegenden Arbeit nicht weiter betrachtet.

Wie es die Benennung auf Englisch Nonlinear AutoRegressive with eXogenous inputs impliziert, zeichnet das NARX-KKN aus, dass es sich im zeitdiskreten Fall zur Berechnung der Ausgänge t_k auf die Rückführung ebendieser Ausgänge und deren Zeitverzögerungen sowie zusätzlich auf externe Eingangsgrößen i_k bzw. deren Zeitverzögerungen bezieht. Die Bezeichnung NARX beschränkt sich nicht auf KNN, sondern beschreibt allgemein Funktionen der zeitdiskreten Form

$$\boldsymbol{t}_{k} = \boldsymbol{f} \left(\boldsymbol{t}_{k-1}, \boldsymbol{t}_{k-2}, \dots, \boldsymbol{t}_{k-n_{\text{FD}}}, \ \boldsymbol{i}_{k-1}, \boldsymbol{i}_{k-2}, \dots, \boldsymbol{i}_{k-n_{\text{ID}}} \right),$$
(3.1)

wobei $n_{\rm FD}$ die höchste Zeitschrittverzögerung der Ausgangsrückführung und $n_{\rm ID}$ die höchste Zeitschrittverzögerung des Eingangs darstellt. Im Falle eines NARX-KNN wird die nichtlineare Funktion f durch ein KNN approximiert. Die allgemeine Struktur der NARX-KNN, unter der Annahme konstanter Anzahl $n_{\rm HN}$ an Neuronen je versteckter Schicht und gleicher Aktivierungsfunktionen σ_i innerhalb einer der $n_{\rm HL}$ Schichten, ist in Bild 3.1 dargestellt. In der Eingangsschicht werden die verzögerten Eingänge $i_{k-n} \in \mathbb{R}^{n_i \times 1}$ und die zeitverzögert zurückgeführten Ausgangsgrößen (auch Zielgrößen genannt) $t_{k-n} \in \mathbb{R}^{n_t \times 1}$ dem KNN zugeführt. Die Verbindungslinien zwischen den Schichten stellen Multiplikationen mit Gewichten dar, welche durch die Gleichungen

$$h_{k_{j,1}}^{\text{KNN}} = \sigma_1 \left(b_{j,1}^{\text{KNN}} + \sum_{n=1}^{n_{\text{ID}}} \boldsymbol{w}_{j,n}^{(0,1)} \boldsymbol{i}_{k-n} + \sum_{n=1}^{n_{\text{FD}}} \boldsymbol{w}_{j,n}^{(n_{\text{HL}+1},1)} \boldsymbol{t}_{k-n} \right), \qquad j = 1, 2, \dots, n_{\text{HN}}, \tag{3.2}$$

$$h_{k_{j,i}}^{\text{KNN}} = \sigma_i \left(b_{j,i}^{\text{KNN}} + \sum_{n=1}^{n_{\text{HN}}} w_{j,n}^{(i-1,i)} h_{k_{n,i-1}}^{\text{KNN}} \right), \qquad j = 1, 2, \dots, n_{\text{HN}}, \qquad (3.3)$$
$$i = 2, 3, \dots, n_{\text{HL}},$$

beschrieben werden. Dabei stellt $h_{k_{j,i}}^{\text{KNN}}$ den Ausgang des *j*-ten Neurons in der *i*-ten Schicht dar, welcher sich durch die Aktivierungsfunktion σ_i der entsprechenden Schicht berechnet. Weiterhin beschreibt $b_{j,i}^{\text{KNN}}$ einen Bias-Term, der auf den Eingang der zugehörigen Aktivierungsfunktion addiert wird. Die Hochstellung zu den Gewichten $\boldsymbol{w}_{j,n}^{(i-1,i)} \in \mathbb{R}^{1 \times n_i}$ für $i = 1, \in \mathbb{R}^1$ für i > 1, außer $\boldsymbol{w}_{j,n}^{(n_{\text{HL}}+1,1)} \in \mathbb{R}^{1 \times n_t}$, kennzeichnet deren Verortung zwischen der i - 1-ten und die *i*-ten Schicht, der erste Index *j* die Zuordnung zum *j*-ten Neuron, der zweite Index die Zuordnung der



Bild 3.1: Allgemeiner Aufbau eines NARX-KNN für eine variable Anzahl an Schichten und darin enthaltener Neuronen. Die Bias-Terme, die additiv in den Eingang der Neuronen mit eingehen, sind exemplarisch nur für die erste Neuronenschicht dargestellt.

Gewichte zu den entsprechenden Eingängen des Neurons. Die Neuronenanzahl der Ausgangsschicht $n_{\text{HL}+1}$ entspricht der Anzahl der Ausgänge n_t , die Neuronenausgänge berechnen sich zu

$$h_{k_{j,n_{\rm HL}+1}}^{\rm KNN} = \sigma_{n_{\rm HL}+1} \left(b_{j,\rm HL}^{\rm KNN} + \sum_{n=1}^{n_{\rm HN}} w_{j,n}^{(n_{\rm HL},n_{\rm HL}+1)} h_{k_{n,n_{\rm HL}}}^{\rm KNN} \right), \qquad j = 1,2,\ldots,n_{\rm t}$$
(3.4)

und können auch als die Ausgänge des KNN t_i bezeichnet werden.

Die Aktivierungsfunktionen können je nach Anwendungsfall variiert werden, die bekanntesten Vertreter sind die lineare Aktivierungsfunktion, die *rectified linear unit* (meist als ReLU abgekürzt), die logistische Funktion und der Tangens hyperbolicus, welche in Bild 3.2 grafisch und mathematisch dargestellt sind. Die Funktionen beeinflussen durch ihre unterschiedlichen Eigenschaften besonders während des Trainings das Konvergenzverhalten. Eine wichtige Anforderung an die Aktivierungsfunktionen in Verbindung mit gradientenbasierten Optimierungsalgorithmen ist die Differenzierbarkeit der Funktionen. Ist diese nicht erfüllt, kann die Anpassung der Gewichte während des Trainings nicht auf Basis des Gradienten bezogen auf die Zielfunktion erfolgen. Strenggenommen ist die ReLU Aktivierungsfunktion an der Stelle 0 nicht differenzierbar, dies stellt aufgrund der Einfachheit der Funktion jedoch praktisch kein Problem dar.



Bild 3.2: Auswahl gängiger Aktivierungsfunktionen innerhalb der Neuronen bei KNN

Damit ein KNN den geforderten Zusammenhang approximativ abbilden kann, müssen die zuvor eingeführten Gewichte und Bias-Terme bestimmt werden. Dies geschieht üblicherweise durch eine Optimierung, welche im Zusammenhang mit KNN auch als Lernvorgang oder als Training bezeichnet wird. Der Lernvorgang wird im nachfolgenden Abschnitt erläutert.

3.2 Lernverfahren für künstliche neuronale Netze

Grundsätzlich wird zwischen drei Arten des Lernens unterschieden [Nel20]:

• unüberwachtes Lernen,

30

- bestärkendes Lernen,
- überwachtes Lernen.

Beim unüberwachten sowie beim bestärkenden Lernen liegen keine Informationen über die wahren Ausgangsgrößen t^* , die das KNN ausgeben soll, vor. Der Unterschied zwischen den beiden Arten liegt darin, dass das unüberwachte Lernen lediglich Informationen aus den Eingangsdaten in den Lernprozess mit einbezieht, während beim bestärkenden Lernen der Netzausgang in jeder Iteration des Lernens anhand eines bestimmten Kriteriums bewertet und nach diesem Kriterium optimiert werden kann. In den häufigsten Fällen, wie auch in der vorliegenden Arbeit, kommt überwachtes Lernen zum Einsatz. Dabei liegen die wahren Ausgangsgrößen t^* vor und die Differenz zwischen den wahren und den vom Netz ausgegeben Ausgangsgrößen t wird während des Lernvorgangs durch Optimierung der Netzparameter minimiert.

Damit ein KNN die Zusammenhänge zwischen den Eingangs- und den Ausgangsgrößen im Rahmen des überwachten Lernens erlernen und anschließend reproduzieren kann, wird ein repräsentativer Trainingsdatensatz benötigt, anhand dessen die Gewichte und Bias-Terme des Netzes angepasst werden. Die Aufbereitung des Datensatzes wird im weiteren Verlauf der Arbeit thematisiert. Jedes Trainingsbeispiel besteht aus einem Paar von Zeitverläufen der Dauer n_k zeitdiskreter Abtastschritte der Eingangsgrößen $I \in \mathbb{R}^{n_i \times n_k}$ und der wahren Ausgangsgrößen $T^* \in \mathbb{R}^{n_t \times n_k}$. Insgesamt werden n_{Train} solcher Trainingsbeispiele zu einem Trainingsdatensatz zusammengefasst. Damit die Differenz zwischen wahrer und vom Netz ausgegebener Ausgangsgröße quantitativ erfasst und optimiert werden kann, ist die Definition eines Kostenfunktionals C_{Train} notwendig. Je nach Problemstellung können unterschiedliche Kostenfunktionen verwendet werden. Ein Beispiel ist der durchschnittliche mittlere quadratische Fehler, welcher sich für den gesamten Trainingsdatensatz berechnet zu

$$C_{\text{Train}} = \frac{1}{n_{\text{Train}}} \sum_{i=1}^{n_{\text{Train}}} \sum_{j=1}^{n_t} \sum_{k=1}^{n_{k_i}} \frac{\left(\boldsymbol{T}_{j,k_i}^* - \boldsymbol{T}_{j,k_i}\right)^2}{n_{k_i}} .$$
(3.5)

Wie im weiteren Verlauf des Kapitels und später in der Anwendung beschrieben, ist es ratsam, die Trainingsdaten aufgrund verschiedener Einheiten und Größenordnungen der Signale vorzuverarbeiten. Dies kann beispielsweise durch eine Normalisierung geschehen, wodurch die Verrechnung unterschiedlicher Einheiten im Kostenfunktional und damit auch eine möglicherweise ungewollte Übergewichtung einzelner Signale umgangen wird. Die iterative Minimierung des Kostenfunktionals C_{Train} ist der eigentliche Lernvorgang und wird durch einen Optimierungsalgorithmus vorgenommen. Es steht eine große Anzahl an verschiedenen Optimierungsalgorithmen zur Auswahl [BHD20]. Ein Beispiel ist der nach Levenberg-Marquardt benannte Algorithmus [Mar63] zur Minimierung des quadratischen Fehlers, welcher sich für viele Beispiele als besonders effizient erwiesen hat [DB04], [ADE20] und eine Kombination aus dem bekannten Gauß-Newton Verfahren und dem klassischen Gradientenverfahren darstellt. Innerhalb des ursprünglichen Algorithmus ist die Bestimmung der Hessematrix H_{Hesse} notwendig, was mit hohem Rechenaufwand verbunden ist. Eine effizientere Implementierung ist durch die Approximation der Hessematrix

$$\boldsymbol{H}_{\text{Hesse}} \approx \boldsymbol{J}^{\text{T}} \boldsymbol{J}$$
 (3.6)

über die Jacobimatrix $J \in \mathbb{R}^{n_t \times n_{p,KNN}}$ möglich. Dabei stellt $n_{p,KNN}$ die Anzahl aller zu bestimmender Parameter im KNN dar. Die Jacobimatrix

$$\boldsymbol{J} = \begin{pmatrix} \frac{\partial C_{\text{Train}_1}}{\partial \boldsymbol{p}_{\text{KNN}}} & \cdots & \frac{\partial C_{\text{Train}_{n_t}}}{\partial \boldsymbol{p}_{\text{KNN}}} \end{pmatrix}$$
(3.7)

enthält die partiellen Ableitungen des Kostenfunktionals für einzelne Ausgänge C_{Train_j} für $j = 1, \ldots, n_t$ nach allen Gewichten w und Bias-Termen b^{KNN} des KNN, welche im Vektor $p_{\text{KNN}} \in \mathbb{R}^{n_{p,\text{KNN}} \times 1}$ zusammengefasst sind. Die Berechnung erfolgt über eine sogenannte Fehlerrückführung (engl. *backpropagation of error*) [RHW85]. Für den Fall rekurrenter KNN wird das Netz über den zeitlichen Strang der Rekurrenz hinweg aufgefaltet und es erfolgt eine sogenannte Fehlerrückführung über die Zeit (engl. *backpropagation through time*). Die Anwendung des Levenberg-Marquardt Algorithmus mit approximierter Hessematrix und Verwendung der Fehlerrückführung ist in [HM94] detailliert beschrieben. Die Änderung aller im KNN vorhandener Parameter Δp_{KNN} während eines Iterationsschrittes folgt der Gleichung

$$\Delta \boldsymbol{p}_{\rm KNN} = \left(\boldsymbol{J}^{\rm T}\boldsymbol{J} + \mu_{\rm LM}\boldsymbol{I}\right)^{-1}\boldsymbol{J}^{\rm T}\boldsymbol{e} \quad , \tag{3.8}$$

wobei μ_{LM} ein Skalierungsfaktor zur Beeinflussung der Schrittweite ist, welcher initial gesetzt wird und dynamisch während des Trainings angepasst werden kann, und $e \in \mathbb{R}^{n_t \times 1}$ das Kostenfunktional für einzelne Ausgänge C_{Train_i} in einem Vektor zusammenfasst.

Des Weiteren erfordert der Levenberg-Marquardt Algorithmus einen initialen Parametersatz p_{KNN_0} , welcher über eine festgelegte Anzahl an Iterationen $n_{Iter,KNN}$ nach Gleichung (3.8) angepasst wird. Die Initialisierung kann auf unterschiedliche Weise erfolgen (z.B. Nullvektor, gleichverteilte oder normalverteilte Zufallswerte etc.) und beeinflusst das Ergebnis z.T. maßgeblich [KK19]. Wird eine nicht deterministische Methode (beispielsweise nach dem Nguyen-Widrow Algorithmus [NW90]) der Initialisierung gewählt, ist es außerdem ratsam, den Lernvorgang mehrfach durchzuführen, um den stochastischen Einfluss zu bestimmen und durch entsprechende Maßnahmen zu berücksichtigen. Die Anzahl der Trainingsiterationen kann anhand des Verlaufs des Kostenfunktionals über die Trainingsiterationen angepasst werden und sollte idealerweise eine Konvergenz gegen einen Endwert aufweisen.

Wie zuvor beschrieben wird während des Trainings eine Minimierung des Kostenfunktionals C_{Train} angestrebt. Dies kann jedoch besonders bei geringer Anzahl an repräsentativer Trainingsdaten und bei relativ dazu großen Netzstrukturen zu Problemen der Überanpassung führen, was auch als Bias-Varianz-Dilemma bekannt ist [Nel20]. Eine Überanpassung äußert sich dadurch, dass das Kostenfunktional für die Trainingsbeispiele einen geringen Wert annimmt, für vom Trainingsdatensatz unabhängige Beispiele (Validierungs- und Testdatensatz) die geforderte Genauigkeit aber nicht erfüllt. Bezogen auf biologische neuronale Netze im menschlichen Gehirn kann es mit dem Auswendiglernen von Informationen verglichen werden. Im Trainingsprogress macht sich Überanpassung wie folgt bemerkbar: In einer Anfangsphase wird das Kostenfunktional für den Trainingsdatensatz und auch für davon unabhängige Beispiele schrittweise verringert. Ab einem bestimmten Iterationsschritt sinkt das Kostenfunktional für die Trainingsdaten zwar weiter, der Fehler bezogen auf davon unabhängigen Daten beginnt jedoch zuzunehmen. Die Generalisierungsfähigkeit des Netzes, also die Fähigkeit zuvor ungesehene Beispiele korrekt zu berechnen, nimmt ab diesem Punkt ab. Um dem entgegenzuwirken, gibt es diverse Möglichkeiten, die als Regularisierung bezeichnet werden. Eine einfache Möglichkeit ist das Weiterführen des Trainings ab derjenigen Iteration abzubrechen, ab der die Überanpassung beginnt. In der englischsprachigen Fachliteratur wird von *early stopping* gesprochen. Ein Überblick zu Regularisierungsmethoden, um dem Problem der Überanpassung zu begegnen, wird unter anderem in [Agg18] gegeben.

Ein Ansatz, der dem frühzeitigen Trainingsabbruch überlegen ist [DB04], stellt die Bayes'sche Regularisierung dar [Mac92]. Dabei wird die Verteilung der Gewichte des KNN als normalverteilt angenommen und das Kostenfunktional um einen Term erweitert, welcher die Werte der Gewichte einbezieht und diese nicht zu groß werden lässt, was letztlich eine Überanpassung vermeidet. Details zur Anwendung der Bayes'schen Regularisierung für das Training von KNN sind [FH97] zu entnehmen.

Zur Durchführung des beschriebenen Trainingsvorgangs ist ein repräsentativer Datensatz notwendig. Die Erstellung, Aufteilung und Vorverarbeitung des Datensatzes hat erheblichen Einfluss auf die Performanz des resultierenden KNN und wird im Folgenden beschrieben.

3.3 Datensatzaufbereitung

Die Datensätze zum Trainieren und Testen bilden das Fundament für den erfolgreichen Einsatz von KNN. Wie zuvor schon erwähnt, setzt sich ein Datenbeispiel jeweils aus einem Paar von Zeitverläufen der Dauer n_k zeitdiskreter Abtastschritte der Eingangsgrößen $I \in \mathbb{R}^{n_i \times n_k}$ und der wahren Ausgangsgrößen $T^* \in \mathbb{R}^{n_t \times n_k}$ zusammen. Die Gesamtheit aller Datenbeispiele wird als Datensatz bezeichnet. Bei der Zusammenstellung des Datensatzes müssen verschiedene Aspekte berücksichtigt werden. Eine grundlegende Voraussetzung an die Signalverarbeitung setzt das Abtasttheorem nach Shannon [Sha49] fest. Demnach müssen die relevanten Signale bei Verwendung von heutzutage üblichen digitalen Sensoren mit einer Abtastfrequenz

$$f_{\rm Abt} \ge 2f_{\rm max},\tag{3.9}$$

also mit mindestens der doppelten maximalen relevanten Frequenz des Systems f_{max} , aufgenommen werden, damit alle relevanten Informationen des Signals erhalten bleiben. In der Praxis wird häufig mit dem 5-10-fachen gearbeitet. Für PKW liegen die typischen Frequenzen der auftretenden Dynamiken beispielsweise bei unter 30 Hz (abgesehen von Anbauteilen wie z.B. Kotflügel oder Auspuff) [Wil98], für LKW sind aufgrund größerer Massen niedrigere Frequenzen anzunehmen.

Des Weiteren ist es erforderlich, dass der Datensatz ausreichend Informationen über den zu erlernenden Zusammenhang enthält. Dabei sollte besonders für nichtlineare Systeme über eine

Variation von auftretenden Amplituden und Frequenzen möglichst der gesamte Arbeitsraum, in dem die Anwendung des KNN vorgesehenen ist, abgedeckt werden. Damit dies gewährleistet wird, ist ein besonderes Augenmerk auf die Auswahl der Eingangsgrößen für die Aufnahme des Datensatzes, welche auch als Anregung bezeichnet werden, zu legen. Weiterführende Informationen zur Wahl des Anregungssignals sind bspw. [Nel20] zu entnehmen. Neben den theoretischen Überlegungen ist auch die praktische Umsetzung der Datenaufnahme zu prüfen. Häufig werden Grenzen der Machbarkeit eines Experiments beispielsweise durch sicherheitsbedingte Restriktionen, besonders für bereits im Serienbetrieb befindliche Systeme, auferlegt.



Bild 3.3: Datenaufteilung in Trainings-, Validierungs- und Testdaten. Die Trainings- und Validierungsdaten werden zum Training und zur Auswahl der Netzarchitektur verwendet, es resultiert ein KNN-Kandidat \hat{f} , welcher in einem finalen Test anhand von unabhängiger Testdaten abschließend überprüft wird und ggf. als beste Lösung gewählt wird.

Neben der reinen Erstellungen des Datensatzes gibt es unterschiedliche Strategien zur Unterteilung des Datensatzes. Besonders wichtig ist dabei, dass der abschließende Test und somit die Festlegung des KNN für die Zielanwendung anhand eines vom Trainingsdatensatz unabhängigen Datensatzes, dem Testdatensatz, erfolgt. Grund dafür ist, dass bei einer abschließenden Bewertung anhand von Beispielen innerhalb Trainingsdatensatzes keine Aussage über die Generalisierungsfähigkeit des Netzes getroffen werden kann. Es besteht die Gefahr der Überanpassung an die Trainingsdaten. Um bereits beim Training einer Überanpassung entgegenzuwirken, ist es üblich einen weiteren Teil des Trainingsdatensatzes zu einem Validierungsdatensatz abzuspalten. Der Validierungsdatensatz wird nicht direkt für die Anpassung der Netzparameter durch den Optimierungsalgorithmus (siehe Abschnitt 3.2), sondern während des Lernvorgangs in einer Art überwachenden Funktion verwendet, indem die Entwicklung des Fehlers auf dem Validierungsdatensatz ausgewertet wird. Dadurch kann bereits während des Trainings Einfluss auf die Generalisierungsfähigkeit genommen werden, beispielsweise durch frühzeitiges Abbrechen des Lernvorgangs. Damit der Trainings-, Validierungs- und Trainingsdatensatz die gewünschte Funktion erfüllen können, ist auch innerhalb dieser Teildatensätze auf eine möglichst breite Abdeckung des Zielarbeitsraums zu achten. Die Aufteilung des Datensatzes in die vorgestellten Teildatensätze ist in Bild 3.3 graphisch dargestellt.

Für den Fall nur weniger zur Verfügung stehender Datenbeispiele sind in [Nel20] weiterführende Aufteilungsstrategien beschrieben.

Ein letzter Aspekt, der einen erheblichen Einfluss auf das Verhalten des Netzes haben kann, ist die Datenvorverarbeitung. Besonders bei Netzen mit mehreren Ein- oder Ausgängen mit unterschiedlichen Größenordnungen kann das Unterlassen einer Vorverarbeitung zu Problemen führen. So erhalten die Ausgänge mit größeren Wertebereichen ggf. ungewollt auch eine höhere Gewichtung in der zu minimierenden Kostenfunktion. Außerdem können unbeschränkte Eingangssignale dazu führen, dass die Aktivierungsfunktionen in gesättigten Bereichen ausgewertet werden, was zu Problemen wie beispielsweise verschwindender und explodierender Gradienten während des Trainings führen kann. Methoden zur Datenvorverarbeitung sind in [PK05] erläutert.

3.4 Auslegung künstlicher neuronaler Netze

Bei der Entwicklung von KNN gilt es neben den Gewichten und Bias-Termen, welche innerhalb des zuvor beschriebenen Lernvorgangs anhand des Trainingsdatensatzes angepasst werden, eine nicht unerhebliche Anzahl von übergeordneten Strukturparametern, häufig als Hyperparameter bezeichnet, festzulegen. Die Hyperparameter bestimmen im Wesentlichen die Topologie des Netzes. Bei ihrer Auswahl besteht ein Zielkonflikt zwischen der resultierenden Genauigkeit für die Zielanwendung und dem Aufwand der Netzsynthese, welcher sich für große Netztopologien besonders im Rechenaufwand während des Lernvorgangs niederschlägt. Ein allgemeingültiges systematisches Verfahren zur Bestimmung der Hyperparameter existiert nicht und ist abhängig von der jeweiligen Anwendung [Mac92], [Han16], [Sin19]. Im Folgenden wird der Einfluss einiger Hyperparameter beschrieben und gängige Methoden zur Bestimmung dieser vorgestellt.

Unverkennbar ist die Bestimmung der Anzahl versteckter Schichten $n_{\rm HL}$ und darin enthaltener Neuronen $n_{\rm HN}$ erforderlich. Im Allgemeinen beschränkt sich der Suchraum nicht auf eine homogene Anzahl von Neuronen pro versteckter Schicht, wie es im Abschnitt 3.1 angenommen wurde, sondern kann beliebig schichtindividuell variiert werden. Nach Kenntnis des Autors gibt es zum aktuellen Stand der Forschung keinen eindeutigen, universal gültigen Ansatz zur Wahl der Netzarchitektur und deren Einfluss. Es bestehen jedoch einzelne Fallstudien zu ausgewählten Problemstellungen [HBB+11] und Ansätze dieser Forschungslücke zu begegnen [MPC+14]. Darüber hinaus zielen weitere Forschungsarbeiten auf eine übergeordnete Optimierung der Netzarchitektur ab [KNS+18], [LNZ+18], was einen deutlich erhöhten Rechenaufwand mit sich bringt. In der Praxis eignet sich häufig ein empirisches Vorgehen zur einfachen Auswahl der Netzarchitektur [CG18], [BFT+19]. Dabei werden, ausgehend von einer relativ geringen Anzahl an Neuronen (aufgrund des vergleichsweise schnellen Lernvorgangs), verschiedene Netzarchitekturen angelernt und verglichen. Die Auswahl des endgültigen Netzes kann anhand bekannter Methoden zur Bestimmung der Modellkomplexität erfolgen wie beispielsweise der Bewertung der Performanz anhand unabhängiger Testdaten, der Kreuz-Validierung oder Verwendung von Informationskriterien [Nel20]. Weiterhin sind die Zeitverzögerungen des Eingangs $n_{\rm ID}$ und der Ausgangsrückführung $n_{\rm FD}$ festzulegen, welche der Systemordnung entsprechen. Auch hierfür ist dem Stand der Forschung kein allgemeingültiges Vorgehen zu entnehmen [Nel20]. Eine Möglichkeit besteht darin, die Auswahl dieser Hyperparameter mit in die empirischen Untersuchungen zur Bestimmung der Netzarchitektur zu integrieren. Dies würde jedoch den Rechenaufwand um den Faktor $n_{\rm ID,max}n_{\rm FD,max}$ erhöhen und ist nicht entkoppelt von der zugrundeliegenden Netzarchitektur zu bewerten. Vielmehr ist eine Methode erstrebenswert, die unabhängig von Modellannahme Aufschlüsse über die Systemordnung liefert, da diese systemimmanent ist. Eine Möglichkeit besteht in der Korrelationsanalyse der Einund Ausgänge zur Aufdeckung signifikanter Zusammenhänge, was erfahrungsgemäß stark von der Systemanregung abhängig ist und nicht immer signifikante Ergebnisse liefert [ZKO⁺21]. Des Weiteren können recht komplexe clusterbasierte Ansätze verwendet werden [FAS04]. Eine weniger rechenintensive und robuste Methode wird von [HA93] vorgeschlagen. Dabei werden sogenannte Lipschitz-Quotienten für ausgewählte Eingänge berechnet und daraus Lipschitz-Indizes bestimmt, welche anschließend zur Bestimmung der Modellordnung verwendet werden.

Neben den Hyperparametern zur Definition der Netzstruktur sind auch die Aktivierungsfunktionen der Neuronen zu wählen. Aufgrund ihrer Differenzierbarkeit haben sich die logistische Funktion und der Tangens hyperbolicus in den versteckten Schichten als besonders geeignet erwiesen [Cal20]. Im Bereich der Bildverarbeitung ist die zuvor erwähnte ReLU Funktion trotz ihrer Unstetigkeit der Sigmoidfunktion überlegen [GBB11]. Grundsätzlich kann für jedes Neuron eine eigene Aktivierungsfunktion bestimmt werden, üblicherweise sind die Aktivierungsfunktionen innerhalb einer Schicht aber konsistent. In der Ausgangsschicht werden lineare Aktivierungsfunktionen präferiert, da diese unbeschränkt in ihrem Ausgabewert sind und der Wertebereich des Ausgangs a priori meist nicht bekannt ist oder nicht begrenzt werden soll.

Zusammenfassend ist festzustellen, dass es bei der Auslegung von KNN eine Vielzahl an Parametern zu bestimmen gibt, die sich darüber hinaus gegenseitig beeinflussen. Obwohl dies eine große Herausforderung darstellt, stellt dieser Abschnitt Lösungsansätze zum Umgang damit dar. Nur durch eine sorgfältige Auswahl der Parameter kann schließlich das volle Potenzial der KNN zu Zustandsschätzung ausgeschöpft werden.

3.5 Fazit

In diesem Kapitel wurden als alternativer Ansatz zur physikalisch motivierten, modellbasierten Zustandsschätzung die Grundlagen der datenbasierten Zustandsschätzung vorgestellt. Dabei liegt der Fokus dieses Kapitels sowie dieser Arbeit auf NARX-KNN, welche nur einen Teil der möglichen datenbasierten Ansätze darstellen. Zu Beginn wurde der allgemeine Aufbau und die Funktionsweise eines NARX-KNN erläutert. Daraus ging bereits hervor, dass die letztendliche Architektur des KNN durch zahlreiche Faktoren beeinflusst wird, die im Entwicklungsprozess des KNN festzulegen sind. Darauf aufbauend wurde zunächst der grundsätzliche Lernvorgang der Netze beschrieben, in

dem die internen Gewichte und Bias-Terme einer zuvor gewählten Netzstruktur durch Optimierung festgelegt werden. Für den zunächst allgemein formulierten Lernvorgang sind in der konkreten Umsetzung Daten notwendig. Daher wurden die Anforderungen an diese Daten sowie deren Aufbereitung und Aufteilung grundlegend erläutert. Abschließend befasste sich dieses Kapitel mit der übergeordneten Auslegung der Netzarchitektur bezüglich der Anzahl der Schichten und der darin enthaltenen Neuronen, der Auslegung der Zeitverzögerungen des Eingangs und der Ausgangsrückführung sowie der Auswahl geeigneter Aktivierungsfunktionen.

Grundsätzlich ist festzuhalten, dass bisher kein standardisiertes Vorgehen zur Entwicklung von KNN zur Zustandsschätzung im Fahrzeugbereich vorliegt. Die dargestellten Inhalte vermitteln ein grundlegendes Verständnis der Problematik und zeigen potentielle Lösungsansätze auf. Im weiteren Verlauf der Arbeit werden die vorgestellten Kenntnisse beispielhaft zur Zustandsschätzung im Sattelzug angewandt und die Ergebnisse diskutiert.

4 Modellierung & Parametrierung der Sattelzugquerdynamik

Die möglichst genaue Abbildung realer Systeme durch Simulationsmodelle ist in vielerlei Hinsicht von Bedeutung. Beispielsweise können Modelle einen Beitrag zur Systemanalyse leisten, was besonders in der frühen Phase der Produktentwicklung Aufschluss über das Verhalten eines noch nicht gefertigten Produktes liefern kann. Somit können unter anderem Fehler und damit einhergehende Kosten frühzeitig verringert werden, wobei die Kosten bekanntermaßen bei zu späteren Entwicklungszeitpunkten auftretenden Fehlern signifikant ansteigen. Darüber hinaus können Simulationsmodelle zur Entwicklung fortschrittlicher Regelalgorithmen, zur Optimierung von Systemen und zur Gewinnung von Informationen über interne, nicht oder nicht fortlaufend messbare, Systemzustände verwendet werden [Nel20]. Auf Letzteres zielt das in diesem Kapitel vorgestellte Modell der Sattelzugquerdynamik ab. Im weiteren Verlauf der Arbeit wird das Querdynamikmodell im Rahmen der zuvor in Kapitel 2 vorgestellten modellbasierten Zustandsschätzung eingesetzt. Die Längsdynamik findet aufgrund fehlenden Zugriffs auf Informationen bezüglich der Eingangsgrößen des Zugfahrzeugs, wie beispielsweise Motormoment oder Antriebsmomente sowie Bremsdruck oder Bremsmoment an den Achsen, keine Berücksichtigung. Lediglich die kinematische Größe der auf den Raddrehzahlen basierenden Fahrzeuglängsgeschwindigkeit im Sattelzug wird dem System als Eingangsgröße zugeführt, wie im weiteren Verlauf noch genauer erläutert.

An Fahrdynamikmodelle, die sich für eine echtzeitfähige Zustandsschätzung im Fahrzeug eignen, werden besondere Anforderungen gestellt. Einerseits ist eine möglichst hohe Genauigkeit gefordert, andererseits darf der damit meist einhergehende Detaillierungsgrad und Rechenaufwand die Leistungsfähigkeit der Zielhardware nicht überschreiten. Diesen Zielkonflikt gilt es bei der Modellierung zu berücksichtigen, wobei die genauen Anforderungen höchst problemspezifisch sind. Dieses Kapitel beinhaltet eine detaillierte Beschreibung des in der vorliegenden Arbeit verwendeten Modells der Sattelzugquerdynamik. Dafür wird ein sogenannter Light-Gray-Box Ansatz verfolgt [IM11], bei dem physikalische Gesetze zur Aufstellung der Modellgleichungen herangezogen und unbekannte Parameter unter Zuhilfenahme von experimentellen Messdaten identifiziert werden. In Abschnitt 4.1 werden zunächst die verwendeten Koordinatensysteme eingeführt. Anschließend folgt eine detailliert begründete Wahl der Modellierungstiefe sowie die Einordnung in die bestehende Literatur. Basierend auf diesen Erkenntnissen folgt die schrittweise Herleitung des querdynamischen Fahrzeugmodells. Die zahlreichen Parameter des resultierenden Modells gilt es bzgl. des in dieser Arbeit eingesetzten Versuchsfahrzeugs zu bestimmen, dies wird in Abschnitt 4.2 genauer beleuchtet. Das Kapitel schließt mit der experimentellen Validierung in Abschnitt 4.3, gefolgt von einem kurzen Fazit. Das Sattelzugquerdynamikmodell inklusive der Parameteridentifikation wurde in [ZKB+19] veröffentlicht.

4.1 Modellierung der Sattelzugquerdynamik

Dieser Abschnitt widmet sich der Herleitung der mathematischen Gleichungen zur Beschreibung der Sattelzugquerdynamik. Grundlage ist ein handelsüblicher Sattelzug bestehend aus einer Zugmaschine und einem Sattelauflieger, skizzenhaft in Bild 4.1 dargestellt. Zur eindeutigen Beschreibung von Positionen und Bewegungsrichtungen sind zunächst Koordinatensysteme festzulegen, bevor die Bewegungsgleichungen des Modell aufgestellt werden.

4.1.1 Koordinatensysteme

Die in dieser Arbeit verwendeten Koordinatensysteme und Begriffe orientieren sich an der DIN ISO 8855 und sind in Bild 4.1 dargestellt [DIN13]. Der Sattelzug lässt sich in zwei Teilsysteme trennen, das Zugfahrzeug und den Sattelauflieger. Nach zuvor genannter Norm liegt der Koordinatenursprung der fahrzeugfesten Koordinatensysteme $(KS)_{F_i}$ in den Schwerpunkten der jeweiligen Teilsysteme, wobei der Index i die Teilsysteme vom Führungsfahrzeug ausgehend nach hinten aufzählt. Für den vorliegenden klassischen Sattelauflieger steht der Index i = 1 für das Zugfahrzeug und i = 2 für den Sattelauflieger. Entsprechend ist die Beschreibung modular für weitere Anhänger anpassbar. Die x_i -Achse entspricht der jeweiligen Fahrzeuglängsachse des Teilsystems i, die y_i -Achse der Fahrzeugquerachse und die z_i -Achse der Fahrzeugvertikalachse. Eine Drehbewegung um die z_i -Achse wird als Gieren bezeichnet und mit dem Gierwinkel ψ_i beschrieben. Drehungen um die x_i - und y_i -Achse werden als Wanken und Nicken bezeichnet und durch den Wankwinkel κ_i bzw. den Nickwinkel φ_i ausgedrückt. Bei Fahrzeugzügen mit mehreren Teilfahrzeugen ist darüber hinaus die relative Orientierung der Teilfahrzeuge zueinander von Interesse. Maßgeblich findet eine relative Verdrehung zueinander um die Vertikalachse statt, welche durch den Knickwinkel θ_i zwischen den Teilfahrzeugen *i* und *i* + 1 beschrieben wird. Darüber hinaus können durch entsprechende Dynamik oder Fahrbahnunebenheiten auch relative Verdrehungen um die Längs- und Querachse auftreten. Zu beachten ist, dass zusammengesetzte Drehungen nicht kommutativ sind und der Einigung auf eine feste Konvention bedürfen, wie beispielsweise auf die aus der Beschreibung von Roboterkinematiken bekannten Kardan-, Euler- oder RPY-Winkel. In der vorliegenden Arbeit werden diese Verdrehungen aufgrund des eher geringen Einflusses auf die Gesamtdynamik und erhöhter Modellkomplexität mit einhergehendem höheren Rechenaufwand vernachlässigt und nicht weiter betrachtet, wie es überwiegend im bestehenden Stand der Forschung ebenfalls gehandhabt wird. Die Vertikalachsen von Zugfahrzeug und Sattelauflieger haben somit stets die selbe Orientierung und die Längs- und Querachsen liegen in zueinander parallelen Ebene.

4.1.2 Wahl der Modellierungstiefe der Sattelzugquerdynamik

Wie bereits in der Einleitung des Kapitels erwähnt, ist bei der Wahl der Modellierungstiefe ein Zielkonflikt zu lösen. Einerseits ist durch ein Modell hohen Detaillierungsgrades eine hohe Genauigkeit



Bild 4.1: Verwendete Koordinatensysteme

und zusätzlicher Informationsgewinn erzielbar, andererseits bringen umfangreiche Modelle diverse Probleme mit sich. Steigender Detaillierungsgrad geht in der Regel mit zunehmender Parameterzahl einher. Dies stellt zusätzliche Herausforderungen an die Parametrierung, insbesondere in Hinblick auf die Robustheit bezogen auf verschiedene Ausführungen des Fahrzeuges (unterschiedliche Bereifung, Reifendruck, Beladung etc.) [Nel20]. Außerdem ist für eine echtzeitfähige Anwendung im Serienfahrzeug besonders auf einen geringen Rechenaufwand zu achten, da die verfügbaren Kapazitäten durch den Kostendruck der Branche üblicherweise stark limitiert sind. Daher werden im Weiteren Modelle, welche die Materialverformungen der Teilfahrzeuge berücksichtigen, von vornherein ausgeschlossen und es wird die Annahme starrer Körper getroffen. Nachfolgend wird ein Überblick zu vorausgegangenen Publikationen erarbeitet, um auf dieser Grundlage die Wahl bezüglich der Modellierungstiefe zu begründen.

Zu Beginn sei wie in der Einleitung in Kapitel 1 erneut darauf hingewiesen, dass obwohl der Sattelzug als eine Fahrzeugeinheit erscheint, die beiden Teilsysteme Zugfahrzeug und Sattelauflieger in vielerlei Hinsicht als separat und grundsätzlich verschieden zu betrachten sind. Ein Grund dafür sind verschiedene Hersteller für Zugfahrzeuge und Sattelauflieger, wobei besonders Sattelauflieger von einer großen Anzahl mittelständischer Unternehmen hergestellt werden. Folglich unterscheiden sich die Teilsysteme deutlich hinsichtlich der Gesamtkosten und der Ausstattung mit elektronisches Komponenten wie Sensoren, Aktoren und Recheneinheiten. Darüber hinaus findet nur ein geringer Informationsaustausch zwischen den Teilsystemen statt, welcher in ISO 11992 vorgeschrieben wird und sich im Wesentlichen auf Größen des EBS bezieht [DIN19]. Dies erschwert es, ohne Kooperation zwischen Herstellern beider Seiten intelligente Funktionen auf Gesamtsystemebene zu realisieren. Die geringe Anzahl von Veröffentlichungen unter Einbeziehung der Längsdynamik spiegelt diesen Sachverhalt wider. Zur adäquaten Abbildung der Längsdynamik sind Kenntnisse über die Brems- und Antriebsmomente beider Teilsysteme notwendig, die nur selten in der Erforschungs- und Entwicklungsphase und zum heutigen Kenntnisstand des Autors überhaupt nicht im Seriensattelauflieger zur Verfügung stehen. Das sind mögliche Gründe dafür, dass die Validierung der Längsdynamikmodelle in [GSM⁺00] anhand von detaillierteren Modellen und nicht experimentell durchgeführt wird und in [KID⁺10] nur simulative Ergebnisse des vorgestellten Beobachters zur Schätzung der Reifenkräfte präsentiert werden. Lediglich mit [GJN⁺20] ist eine Publikation mit Validierung anhand realer Messdaten bekannt. Aufgrund der Tatsache, dass dem Autor keine Informationen zu längsdynamischen Eingangsgrößen des Zugfahrzeugs zur Verfügung stehen, wird die Längsdynamik vernachlässigt und in Anlehnung an weitere Publikationen (z.B. [VD97], [Geh00], [CC11], [KLF13], [Alb13], [SJL14], [MC15]) die Längsgeschwindigkeit als Eingangsgröße verwendet.

Die Modellierung der Querdynamik von Sattelzügen ist in ihren ersten Ansätzen auf [Wil51] zurückzuführen. Über ein Jahrzehnt später wird mit [Jin66] ein lineares Querdynamikmodell eines Sattelzuges mit zusätzlichem Anhänger präsentiert, welches sich zunächst als Standardmodell zur Stabilitätsanalyse solcher Fahrzeuge etablierte, während ab den 1990er Jahren Wissenschaftler wieder zu Herleitung eigener Modelle tendieren [BNH19]. Grundsätzlich lassen sich bei der Modellbildung Einspur- und Zweispurmodelle unterscheiden. Einspurmodelle sind relativ einfache Modelle, welche vereinfachend das linke und rechte Rad jeder Achse zu einem Rad in der Mitte der Achse zusammenfassen, während Zweispurmodelle jedes Rad einzeln berücksichtigen wie in Bild 1.3 im Stand des Wissens dargestellt. Zur Abbildung der Reifenkräfte in beiden Modelltypen können lineare und nichtlineare Reifenmodelle eingesetzt werden, welche im nachfolgenden Abschnitt genauer betrachtet werden. Die Auswahl des Fahrdynamikmodells und des Reifenmodells hängt vom jeweiligen Anwendungsfall und den vorliegenden Randbedingungen ab, im Folgenden wird dies weiter beleuchtet.

Zweispurmodelle eignen sich besonders dann, wenn das Modell für radselektiven Erkenntnisgewinn eingesetzt werden soll oder radselektive interne Größen das Systemverhalten hinsichtlich der anwendungsspezifischen Zielgrößen signifikant beeinflussen. Für den Sattelzug ist das Zweispurmodell in der wissenschaftlichen Literatur eher selten vertreten. Dies kann darauf zurückzuführen sein, dass einerseits Sattelzüge im realen Anwendungsumfeld nur geringfügig querdynamischer Anregung ausgesetzt sind, andererseits Zweispurmodelle bei Fahrzeugen mit großer Anzahl an Achsen im Vergleich zu Einspurmodellen erheblich mehr Parameter aufweisen. Im Falle des in Europa hauptsächlich vorkommenden Sattelzugs beträgt die Anzahl der Achsen 5, 2 in der Zugmaschiene und 3 im Sattelauflieger. Bei Reifenmodell mit dynamischem Kraftaufbau steigt zusätzlich die Anzahl der Zustände an. Insgesamt kann sich das als nachteilig bezogen auf Parametrierung und Recheneffizienz auswirken. In [CT95] wird ein nichtlineares Zweispurmodell mit linearem Reifenmodell zur Analyse der Fahrdynamik vorgestellt. Für die regelungstechnische Anwendungen wird daraus ein lineares Modell abgeleitet und mit dem ursprünglichen Modell im Rahmen von Simulationen verglichen. Dabei zeigt sich für geringe querdynamische Anregungen (Lenkwinkel kleiner 4°) eine recht gute Übereinstimmung. Größere Winkel werden nicht betrachtet. Das in [OKA12] vorgestellte Zweispurmodell beinhaltet hingegen ein nichtlineares Reifenmodell, anhand dessen eine Regelung zur Spurfolge des Sattelaufliegers untersucht wird. Die Bewertung dieser

43

Modelle hinsichtlich ihrer Abbildungsgüte bezogen auf einen realen Sattelzug ist schwierig, da in beiden Arbeiten keine Validierung anhand experimenteller Daten vollzogen wird, wie es beispielsweise in [LG04] und [KLF13] vorgestellt wird. Diese beiden Publikationen nutzen nichtlineare Reifenmodelle nach Pacejka [PB92] und zeigen eine gute Übereinstimmung zwischen Modell und experimentell erfassten Daten. Allerdings werden in beiden Fällen erneut lediglich Validierungsmanöver mit geringer querdynamischer Anregung (Gierraten kleiner $\sim 10^{\circ} \text{ s}^{-1}$) präsentiert, welche kaum die modellierten Nichtlinearitäten (z.B. Schräglaufwinkel im nichtlinearen Bereich der Reifenquerkräfte oder Winkelbeziehungen außerhalb des Bereichs mit gültiger Kleinwinkelnäherung) anregen. Somit ist die Genauigkeit der Modelle und die Notwendigkeit zur Berücksichtigung bestimmter Nichtlinearitäten im genannten Bereich nicht zu bewerten. Zu erwarten ist demnach die Erkenntnis in [LG04], dass ein zum Vergleich herangezogenes einfacheres, lineares Modell die Bewegung in der Ebene mit ähnlicher Güte abbildet.

Einspurmodelle zur Beschreibung der Sattelzugquerdynamik kommen vergleichsweise häufiger im Umfeld wissenschaftlicher Veröffentlichungen vor. Am häufigsten werden lineare Modelle mit linearen Reifenmodellen zur Abbildung der Reifenkräfte verwendet [Jin66], [TT08], [TC09], [Lui10], [CC11], [Alb13], [SJL14], [Wol14], [MC15], [BNH19]. Diese Modelle sind zwar aufgrund ihrer geringen Komplexität einfach herzuleiten und besonders recheneffizient, weisen allerdings auch einen entscheidenden Nachteil auf. Ihre Gültigkeit beschränkt sich auf kleine Winkel (bezogen auf alle auftretenden Winkelgrößen wie Lenkwinkel, Knickwinkel, Schwimmwinkel, Schräglaufwinkel etc.) zur Eliminierung der damit einhergehenden Nichtlinearitäten aus trigonometrischen Zusammenhängen. So wird beispielsweise im Rahmen der Kleinwinkelnäherung der Sinus durch $\sin(x) \approx x$ und der Kosinus durch $\cos(x) \approx 1$ approximiert. Für einen Knickwinkel von 30°, der bereits bei Kreiseldurchfahrten erreicht wird, beträgt der Fehler durch die Kosinusapproximation in den entsprechenden Termen ungefähr 15 %. Somit sind lineare Einspurmodelle nur bedingt im realen Umfeld einsetzbar [CC11]. In [VD97] und [GJN+20] werden nichtlineare Einspurmodelle mit Reifenmodellen nach Pacejka [PB92] vorgestellt. In beiden Veröffentlichung wird der verzögerte Aufbau der Reifenquerkräfte durch Verzögerungsglieder erster Ordnung berücksichtigt. Die erzielten Ergebnisse werden anhand experimenteller Ergebnisse erfolgreich validiert. Darüber hinaus erfolgt in [GJN+20] ein Vergleich verschiedener Modellierungstiefen (nichtlineares Zweispurmodell, lineares Einspurmodell) mit daraus folgender Empfehlung zum nichtlinearen Einspurmodell nach Abwägung von Genauigkeit und Recheneffizienz.

Aus den Erkenntnissen der genannten Untersuchungen wird für den modellbasierten Ansatz der Schätzung von Knickwinkel und Reifenquerkräften im realen Einsatzbereich von Sattelzügen unter der Anforderung möglichst geringen Rechenaufwands ein nichtlineares Einspurmodell mit einem nichtlinearen Reifenmodell gewählt. Für die Zielgröße Knickwinkel ist keine radselektive Zustandsinformation notwendig. Die Gültigkeit des Modells und somit auch die der darauf aufbauenden Schätzalgorithmen soll für den im Serieneinsatz üblichen Bereich gegeben sein. Dies erfordert ein nichtlineares Modell des Sattelzugs und der Reifenquerkräfte, insbesondere für enge Kurvenfahrten. Aus internen Untersuchungen sowie aus [LMD⁺02] geht hervor, dass besonders zwischen den drei Sattelaufliegerachsen ein unterschiedlicher Lasteintrag und damit einhergehend unterschiedlicher Verschleiß auftritt. Ein signifikanter Unterschied zwischen linkem und rechtem Reifen ist dem Autor hingegen nicht bekannt. Um den Rechen- und Parametrierungsaufwand gering zu halten, erscheint daher auch für die Zielgröße der Reifenquerkraft ein Einspurmodell mit den achsselektiven Zuständen der Reifenquerkräfte als ausreichend. Für die Abbildung der Reifenkräfte bestehen umfassende Vorarbeiten. Im nachfolgenden Abschnitt wird ein Überblick über diese gegeben und das gewählte Reifenmodell vorgestellt.

4.1.3 Modellierung des Reifen-Fahrbahn Kontakts

Die Reifenkräfte stellen den Kontakt zwischen Fahrzeug und dem befahrenen Untergrund dar und beeinflussen maßgeblich die Fahrdynamik. Der Zusammenhang zwischen Ursache und Wirkung ist komplex und detaillierte Beschreibungen sind der einschlägigen Literatur zu entnehmen [MW14], [Pac12], [Kol09]. Hauptsächlich treten zwei Effekte auf, einerseits die Adhäsion, welche eine Kraft zwischen den Reibpartnern auf atomarer Ebene beschreibt, andererseits die Hysterese, welche durch die innere Reibung des Reifengummis bei Verformung entsteht und ebenfalls in einer Kraft resultiert. Zur Einbeziehung dieser Effekte innerhalb des Fahrdynamikmodells bestehen Reifenmodelle unterschiedlichster Komplexität, welche sich nach [Pak01] grob in vier Kategorien einteilen lassen.

Einfache Ersatzmodelle

Besonders recheneffizient und einfach zu parametrieren ist die Annahme linearer Zusammenhänge zwischen der auftretenden Reifenkraft und der dazugehörigen Schlupfgröße. Für die Reifenquerkraft F_y ist dies der Schräglaufwinkel α , welcher den Winkel zwischen Reifenlängsachse und Geschwindigkeitsvektor v_R im Radaufstandspunkt beschreibt und in Bild 4.2(a) dargestellt ist. Für die Reifenlängskraft F_x ist dies der Längsschlupf λ , welcher sich aus einer auftretenden Relativgeschwindigkeit zwischen Fahrzeugaufbau- und Rotationsgeschwindigkeit des Rads ergibt. Mit den entsprechenden Reifenkraftbeiwerten c_{α} (auch als Schräglaufsteifigkeit bezeichnet) und c_{λ} gilt

$$F_y = -c_\alpha \alpha, \tag{4.1}$$

$$F_x = -c_\lambda \lambda. \tag{4.2}$$

Ein kombinierter Schlupfzusammenhang, wie er aus dem Kamm'schen Kreis hervorgeht, findet keine Berücksichtigung. Aus zuvor benannten Gründen (vgl. Einleitung des Kapitels 4) werden die Reifenlängskräfte innerhalb dieser Arbeit ohnehin nicht betrachtet. Derartige Modelle gelten nur für kleine Schlupfgrößen, für die die Reifenkraftschluss-Schlupfkurve linear verläuft. Daher eignen sie sich nur für ausgewählte Anwendungen.

Physikalische Modelle

Physikalische Modelle zielen darauf ab, die Kraftübertragung detailliert durch mechanische Grundbausteine wie Federn und Dämpfer abzubilden und diesen eine physikalische Bedeutung zuzuordnen. Die Parameter können größtenteils aus geometrischen Daten und Materialeigenschaften gewonnen werden. Bekannte Vertreter physikalischer Reifenmodelle sind das LuGre- [COA⁺95], FTire [Gip99], SWIFT- [SBH⁺05] und das Brush-Modell [SGB⁺09]. Je nach Ausprägung sind diese Modelle nicht immer für die Echtzeitanwendung einsetzbar.

Detaillierte FEM-Modelle

Finite Elemente Methode (FEM)-Modelle sind hoch detaillierte Modelle auf Basis einer FEM-Struktur des zu untersuchenden Reifens. Der hohe Freiheitsgrad erlaubt eine sehr detaillierte Betrachtung und somit die Untersuchung sehr spezieller Fragestellungen bezüglich der Kontaktzone zwischen Reifen und Fahrbahn, was beispielsweise Aussagen über Abrieb, Rollwiderstand, Temperaturverteilung, Aquaplaningverhalten oder Geräuschentwicklung treffen lässt. In der Regel sind solche Modelle sehr rechenaufwendig und nicht echtzeitfähig [Kol09]. Daher kommen sie für die Problemstellung in dieser Arbeit nicht in Frage.

Mathematische Modelle

Mathematische Reifenmodelle zeichnen sich dadurch aus, dass die zugrundeliegende Motivation nicht auf der Abbildung der physikalischen Phänomene beruht, sondern auf der mathematischen Approximation gemessener Kennfelder durch Ansatzfunktionen. Diese Funktionen beschreiben den quasi-stationären Zusammenhang zwischen den auftretenden Schlupfgrößen Schräglaufwinkel α sowie Längsschlupf λ und den daraus resultierenden Reifenkräften im Allgemeinen in nichtlinearer Form. Die Modelle finden im Regelfall einen guten Kompromiss zwischen Genauigkeit und Rechenaufwand, was sie für Echtzeitanwendungen besonders attraktiv macht. Sie unterscheiden sich im Wesentlichen durch ihre Ansatzfunktionen [Kol09]. Beispiele sind das Kiencke- [KN05] und das Burckhardt-Modell [BR93]. Besonders häufig zitiert und verwendet wird das so genannte Magic Formula Tire Model (MFTM) nach [PB92]. Das MFTM kommt in unterschiedlichen Varianten vor und zeichnet sich dadurch aus, dass es mit einem Satz trigonometrischer Funktionen einheitlich Reifenlängs- und Reifenquerkräfte abbilden kann. Im Rahmen dieser Arbeit wird zur Abbildung der Reifenquerkräfte ebenfalls das MFTM ausgewählt und daher im Folgenden in seinen Grundzügen erläutert.

Der Hauptbestandteil des MFTM ist die aus trigonometrischen Funktionen zusammengesetzte Magic Formla

$$F_{0_{x,y}}(s) = D\sin\left(C_s \arctan\left(B_s s - E_s\left(B_s s - \arctan\left(B_s s\right)\right)\right)\right),\tag{4.3}$$

welche aus der Eingangsgröße des entsprechenden Schlupfs *s* die dazugehörige quasi-stationäre Reifenkraft unter reiner Längs- oder Querdynamik berechnet. Für die Reifenlängskraft F_{0_x} wird für *s* der Längsschlupf λ und für die Reifenquerkräfte F_{0_y} der Schräglaufwinkel über $\tan(\alpha)$ eingesetzt. Die Koeffizienten in Gleichung (4.3) berechnen sich zu

$$D = \mu_{\max} F_z, \tag{4.4}$$

$$B_s = \frac{C_{\rm Fs}}{C_s D}, \, \text{mit}$$
(4.5)

$$C_{\rm Fs} = c_{1_s} \sin\left(2 \arctan\left(\frac{F_z}{c_{2_s}}\right)\right),\tag{4.6}$$

mit dem maximalen Reibwert μ_{max} , der Radaufstandskraft F_z . Die entsprechend zur Längs- und Querrichtung gehörenden Parameter E_s , C_s , c_{1_s} und c_{2_s} charakterisieren die Magic Formula und sind empirisch zu ermitteln. Der qualitative Verlauf für die resultierende Reifenquerkraft bei anliegendem Schräglaufwinkel ist in Bild 4.2(b) dargestellt. Die auftretenden Parameter lassen gewissermaßen eine Interpretation zu. So beschreibt D die maximal mögliche Reifenkraft in Längsbzw. Querrichtung. Das Produkt aus $B_sC_sD_s$ entspricht der Steigung im Ursprung, welche in Querrichtung der Schräglaufsteifigkeit c_{α} des einfachen Ersatzmodells aus Gleichung (4.1) gleicht, wobei B_s als Steifigkeitsfaktor bezeichnet wird und maßgeblich die Steigung beeinflusst, während C_s eher die Form des weiteren Verlaufs der Funktion prägt. Der Parameter E_s erlaubt eine feinere Einstellung der Krümmung um den Maximalwert und damit einhergehend die horizontale Position des Maximums.



Bild 4.2: Beschreibung relevanter Größen des Reifenquerkraftmodells und deren Abhängigkeiten

Bei gleichzeitig auftretendem Längsschlupf und Schräglaufwinkel wird gemäß des Kamm'schen Kreises in Gleichung (4.3) eine Gewichtungsfunktion in Abhängigkeit von λ und α eingeführt. Umfangreiche Ausführungen dazu sowie im Allgemeinen zur Reifendynamik sind [Pac12] zu

entnehmen. Aufgrund der vernachlässigten Längsdynamik in dieser Arbeit wird darauf nicht weiter eingegangen und auch im weiteren Verlauf lediglich die Reifenquerkraft thematisiert. Die bisherigen Gleichungen zur Abbildung des Zusammenhangs zwischen Schräglaufwinkel α und dabei auftretender Reifenquerkraft F_{0_y} gelten für den quasi-stationären Fall. Bei abrupten Lenkmanövern wird diese Annahme jedoch nicht erfüllt. Die Reifenquerkraft baut sich bei verändertem Schräglaufwinkel nur verzögert auf, was auf die Nachgiebigkeit des Reifengummis zurückzuführen ist. Um dieses Verhalten zu berücksichtigen, wird die Dynamik des Kraftaufbaus durch ein Verzögerungsglied erster Ordnung gemäß

$$F_y + \frac{\ell_{\rm R}}{v_x} \dot{F}_y = F_{0_y} \tag{4.7}$$

abgebildet, mit der Einlauflänge $\ell_{\rm R}$ und der Fahrzeuglängsgeschwindigkeit v_x [VD97], [DVC⁺09], [MW14].

Das nichtlineare MFTM mit verzögertem Reifenkraftaufbau eignet sich besonders für die Problemstellung dieser Arbeit, da mit wenigen Parametern die Reifenquerkräfte auch für große Schräglaufwinkel, wie beispielsweise bei engen Kurvenfahrten, präzise abgebildet werden können. Aus weiterführenden Untersuchungen ist hervorgegangen, dass für die Modellierung der Reifenquerkräfte des Sattelzugs der Einfluss durch den Parameter E vernachlässigbar klein ist. Dies ist darauf zurückzuführen, dass die Reifenquerkraft im Sattelauflieger über den Schräglaufwinkel in der Messung kein Maximum ausbildet [VD97], [Leh15], wie es besonders in der Längsdynamik, aber auch in der Querdynamik bei PKW auftritt. Vielmehr verhält sie sich monoton steigend, bis eine Sättigung eintritt. Deshalb wird im weiteren Verlauf der Arbeit E = 0 gesetzt. Nach Auswahl der Modellierungstiefe für das Sattelzugquerdynamikmodell inklusive eines geeigneten Reifenmodells kann im Folgenden die Herleitung der Bewegungsgleichungen erläutert werden.

4.1.4 Bewegungsgleichungen der Sattelzugquerdynamik

Grundsätzlich bestehen verschiedene Prinzipien zum Aufstellen der Bewegungsgleichungen für mechanische Systeme, die bekanntesten darunter sind das Newton'sche Prinzip, das Prinzip von d'Alambert, das Prinzip der virtuellen Arbeit und die Lagrange'sche Vorschrift [Wil98], [Woe16]. Die Auswahl erfolgt üblicherweise nach persönlicher Präferenz und einer möglichst unkomplizierten Anwendung für das zugrundeliegende System. Im Rahmen dieser Arbeit wurde das Newton'sche Prinzip angewandt, Details sind in o.g. Literatur nachzuschlagen.

Zur Herleitungen der Bewegungsgleichungen wird das Freikörperbild in Bild 4.3 herangezogen. Der Sattelzug ist aus der Vogelperspektive dargestellt und in die beiden Teilsysteme Zugfahrzeug und Sattelauflieger unterteilt. Aus den Erläuterungen in Abschnitt 4.1.2 geht die Motivation für das Einspurmodell hervor. Im Freikörperbild wird dieses durch die abstrahierte Zusammenfassung der linken und rechten Spur zu einem einzigen Rad pro Achse, dessen Position auf der Längsachse angenommen wird, deutlich.



Bild 4.3: Freikörperbild des Sattelzugs zur Herleitung der Bewegungsgleichungen der Querdynamik mit allen berücksichtigten Kräften, Eingängen und Bewegungsgrößen. Die Systemzustände sind in rot gekennzeichnet, die Eingänge in blau.

Der Impulssatz in Richtung der Fahrzeugquerachse y_i und der Drallsatz in den Schwerpunkten um die Hochachse z_i ergeben für das Zugfahrzeug

$$m_1\left(\dot{v}_{y_1} + \dot{\psi}_1 v_{x_1}\right) = F_{y_{11}}\cos\left(\delta\right) + F_{y_{12}} + H\cos\left(\theta\right),\tag{4.8}$$

$$J_1 \tilde{\psi}_1 = a_1 F_{y_{11}} \cos\left(\delta\right) - b_{12} F_{y_{12}} - h_1 H \cos\left(\theta\right), \tag{4.9}$$

und für den Sattelauflieger

$$m_2\left(\dot{v}_{y_2} + \dot{\psi}_2 v_{x_2}\right) = F_{y_{21}} + F_{y_{22}} + F_{y_{23}} - H,$$
(4.10)

$$J_2 \ddot{\psi}_2 = -a_2 H - b_{21} F_{y_{21}} - b_{22} F_{y_{22}} - b_{23} F_{y_{23}}.$$
(4.11)

Die auftretenden Kräfte führen zu einer translatorischen Beschleunigung der Teilsystemmassen m_i und mit ihren entsprechenden Hebelarmen zu einer Gierbeschleunigung $\ddot{\psi}_i$ mit dem Gierträgheitsmoment J_i . Eingeleitet durch den Lenkwinkel δ erfahren die Räder einen Schräglaufwinkel, welcher zu sich aufbauenden Reifenquerkräften führt. Die Reifenquerkräfte F_{ij} werden über den Index *i* den Teilsystemen mit dem Zugfahrzeug anfangend in entgegen der Fahrtrichtung aufsteigenden Nummerierung zugeordnet und über den Index *j* in der selben Zählrichtung den Achsen des jeweiligen Teilsystems zugewiesen. Die dazugehörigen Schräglaufwinkel α_{ij} berechnen sich zu

$$\alpha_{11} = \delta - \arctan\left(\frac{v_{y_1} - a_1\dot{\psi}_1}{v_{x_1}}\right),\tag{4.12}$$

für die erste Achse des Zugfahrzeugs sowie zu

$$\alpha_{ij} = -\arctan\left(\frac{v_{y_i} + b_{ij}\dot{\psi}_i}{v_{x_i}}\right) \tag{4.13}$$

für alle anderen Achsen des Sattelzugs und ist grafisch im Allgemeinen in Bild 4.2(a) dargestellt. Die Längen a_1 und a_2 stehen für den Abstand der ersten Zugfahrzeugachse bzw. des Königszapfen zum Schwerpunkt des jeweiligen Teilsystems, b_{ij} für die Abstände vom Schwerpunkt zu den übrigen Achsen. Für die Berechnung der auftretenden Reifenquerkräfte über das in Abschnitt 4.1.3 vorgestellte Reifenmodell sind die Radaufstandskräfte notwendig. Es werden statische und im Sattelauflieger über die Achsen homogen verteilte Reifenaufstandskräfte angenommen, da eine separate Betrachtung der Sattelaufliegerachsen zu einem unterbestimmten Gleichungssystem bei der Berechnung der Aufstandskräfte führt. Als vereinfachtes Ersatzfreikörperbild wird ein Sattelauflieger mit lediglich der mittleren Achse betrachtet, deren Aufstandskraft homogen auf die tatsächlichen 3 Achsen verteilt wird. Unter den genannten Annahmen ergeben sich folgende Radaufstandskräfte:

$$F_{z_{11}} = m_1 g \frac{b_{11}}{l_1} - m_2 g \frac{b_{22}}{(a_2 + b_{22}) l_1} e_1, \tag{4.14}$$

$$F_{z_{12}} = m_1 g \frac{a_1}{l_1} + m_2 g \frac{b_{22} \left(l_1 + e_1\right)}{\left(a_2 + b_{22}\right) l_1} e_1, \tag{4.15}$$

$$F_{z_{2j}} = \frac{m_2 g_{\overline{(a_2+b_{22})}}}{3}, \qquad \forall j = 1, 2, 3, \qquad (4.16)$$

mit der Gravitationskonstante g und den additiv zusammengefassten Längen $l_1 = a_1 + b_{11}$ und $e_1 = b_{11} - h_1$.

Die beiden Teilsysteme sind über den Königszapfen kinematisch gekoppelt und die Koppelkraft Hin Sattelaufliegerquerrichtung, welche mit dem Abstand h_1 zum Schwerpunkt des Zugfahrzeugs an diesem angreift, beschreibt die Interaktion dazwischen. Die Koppelkraft in Längsrichtung wird in Konformität mit der nicht betrachteten Längsdynamik vernachlässigt. Über die kinematische Zwangsbedingung

$$v_{y_2} + a_2 \dot{\psi}_2 = \left(v_{y_1} - h_1 \dot{\psi}_1 \right) \cos\left(\theta\right) - v_{x_1} \sin\left(\theta\right)$$
(4.17)

für die Quergeschwindigkeit und

$$v_{x_1} = \cos(\theta) v_{x_2} - \sin(\theta) \left(v_{y_2} + a_2 \dot{\psi}_2 \right)$$
 (4.18)

für die Längsgeschwindigkeit im Koppelpunkt wird die feste Verbindung der beiden Teilsysteme garantiert. Die Knickwinkelrate $\dot{\theta}$ steht gemäß

$$\dot{\theta} = \dot{\psi}_2 - \dot{\psi}_1 \tag{4.19}$$

im Zusammenhang mit den Gierraten der Teilsysteme.

Wird für die Reifenkräfte das MFTM, unter Einbeziehung des dynamischen Reifenkraftaufbaus entsprechend der Gleichung (4.7), substituiert, Gleichung (4.17) in (4.8) eingesetzt, die Koppelkraft H durch Umformung der Gleichungen (4.8) - (4.11) eliminiert und schließlich Gleichung (4.17) nach der Zeit differenziert, entsteht ein Satz aus $n_x = 10$ Systemgleichungen. Diese lassen sich in die allgemeine Form der nichtlinearen Zustandsraumdarstellung aus (2.1) - (2.2) in Abschnitt 2.1 überführen, welche die Zustände

$$\boldsymbol{x} = \begin{pmatrix} v_{y_1} & \dot{\psi}_1 & v_{y_2} & \dot{\psi}_2 & \theta & F_{y_{11}} & F_{y_{12}} & F_{y_{21}} & F_{y_{22}} & F_{y_{23}} \end{pmatrix}^{\mathrm{T}} \qquad \in \mathbb{R}^{n_x}, \tag{4.20}$$

und die $n_u = 2$ Eingänge

$$\boldsymbol{u} = \begin{pmatrix} \delta \\ v_{x_2} \end{pmatrix} \in \mathbb{R}^{n_u} \tag{4.21}$$

aufweist. Die Messgleichung gestaltet sich in Abhängigkeit von der eingesetzten Sensorik. Wie im weiteren Verlauf der Arbeit beschrieben, beschränkt sich die Anzahl der Messgrößen im Serienfahrzeug auf $n_y = 1$ mit der Gierrate im Sattelauflieger, was zu der Messgleichung

$$y = \dot{\psi}_2 \qquad \qquad \in \mathbb{R}^{n_y}, \tag{4.22}$$

führt, während für die Identifikation und Validierung des Modells und der Schätzalgorithmen im Versuchsfahrzeug

$$\boldsymbol{y}_{\text{Ident}} = \begin{pmatrix} \dot{\psi}_1 & \dot{\psi}_2 & \theta & F_{y_{21}} \end{pmatrix}^{\text{T}} \qquad \in \mathbb{R}^{n_{y_{\text{Ident}}}}, \qquad (4.23)$$

mit $n_{y_{\text{Ident}}} = 4$ zur Verfügung stehen, da für die experimentelle Erprobung zusätzliche über den Serienstand hinausgehende Sensoren verbaut sind. Nachdem die Systemgleichungen in zeitkontinuierlicher Form aufgestellt sind, werden sie entsprechend der zu Beginn des Abschnitts 2.3 beschriebenen expliziten Diskretisierung nach Euler mit einem Abtastintervall T = 10 ms (vgl. nachfolgender Abschnitt) in eine zeitdiskrete Form (vgl. Gleichung (2.10) - (2.11)) überführt. Dadurch wird eine Implementierung auf digitalen Recheneinheiten ermöglicht, wie es für die nachfolgend beschriebene Parameteridentifikation und schließlich auch für die digitale Realisierung des Schätzalgorithmus auf einer Zielhardware notwendig ist.

4.2 Parametrierung

Das im Abschnitt 4.1 beschriebene Modell beinhaltet insgesamt 27 Modellparameter, die es bezüglich des Versuchsträgers zu parametrieren gilt. Einige der Parameter lassen sich durch Messungen relativ einfach bestimmen und bleiben weitestgehend über den Produktlebenszyklus konstant. Andere können nur mit erhöhtem experimentellen Aufwand ermittelt werden und unterliegen darüber hinaus potenziell erheblichen Schwankungen. In diesem Abschnitt wird zunächst der in dieser Arbeit betrachtete Versuchsträger vorgestellt und anschließend die Parametrierung des zuvor beschriebenen Querdynamikmodells des Sattelzugs mit Bezug auf den Versuchsträger thematisiert.

4.2.1 Versuchsträger und Sensorik

Bei dem in der vorliegenden Arbeit eingesetzen Versuchsfahrzeug handelt es sich um einen handelsüblichen Sattelzug. Das Zugfahrzeug ist ein DAF XF und der Sattelauflieger mit Schiebeplanen an den Seiten ist ein Produkt des Fahrzeugbauers August Schmidt GmbH & Co. KG. In Bild 4.4 ist das Fahrzeug abgebildet, die Tabellen 4.1 und 4.2 enthalten Informationen über die beiden Teilfahrzeuge. Zur synchronisierten Messdatenaufnahme kommt ein SIRIUS Datenerfassungssystem der Firma DEWESoft zum Einsatz. Dieses ermöglicht sowohl analoge, als auch digitale Sensorsignale sowie Kamerabilder aufzunehmen. Die Abtastfrequenz f_{Abt} wird für alle Signale zu 100 Hz gewählt. Dies entspricht der Abtastfrequenz der serienmäßig aufgenommen Signale. Bei den verwendeten Messsignalen und deren Quellen ist zwischen Zusatzsensorik, welche zur Entwicklung und Validierung von Modellen und Methoden verwendet wird, und im Serienzustand des Fahrzeugs verfügbaren Sensoren zu unterscheiden. Diese lassen sich darüber hinaus in im Sattelauflieger in der Serienanwendung zugängliche und nicht zugängliche Größen unterteilen. Nachfolgend werden die verwendeten Signale und deren Quellen sukzessive erläutert.



Bild 4.4: Versuchsfahrzeug

Tabelle 4.2:	Daten	Sattelauflieger
--------------	-------	-----------------

Serienmäßiger CAN Bus zwischen Zugfahrzeug und Sattelauflieger nach ISO 11992

Die Steuergeräte, Aktoren und Sensoren in kommerziellen Fahrzeugen kommunizieren üblicherweise über einen Controller Area Network (CAN) Bus. Dabei handelt es sich um ein Bussystem mit gleichberechtigten Teilnehmern ohne Hostrechner, welches nach einem nachrichtenbasierten Kommunikationsprotokoll funktioniert. Somit kann jeder Teilnehmer innerhalb des Bussystems lesen und schreiben. Die Abfolge und Priorisierung der Nachrichten erfolgt über eine Identifizierungsnummer der Nachrichten, welche zu Beginn des Informationsrahmens, entsprechend eines einheitlichen Protokolls, festgelegt ist, auf den Bus gesendet wird. Die einzige im Serienauflieger verfügbare und somit bedeutsamste Signalquelle ist der CAN Bus zwischen Zugfahrzeug und Sattelauflieger, welcher nach ISO 11992 für Nutzfahrzeuge mit einem oder mehreren Anhängern vorgeschrieben ist [DIN19]. Der Informationsgehalt ist relativ beschränkt und ist maßgeblich zur Kommunikation zwischen den elektronischen Bremssystemen der Teilfahrzeuge gedacht. Die für diese Arbeit relevanten Signale sind die Fahrzeuglängsgeschwindigkeit des Sattelaufliegers v_{x_2} und die Differenz der Radgeschwindigkeiten Δv zwischen linkem und rechtem Rad der mittleren Sattelaufliegerachse. Die Radgeschwindigkeitsdifferenz von nicht angetriebenen Achsen kann verwendet werden, um daraus mit der Spurweite ℓ_{Spur} die Gierrate zu berechnen [WHL+15]:

$$\dot{\psi} = \frac{\Delta v}{\ell_{\rm Spur}}.\tag{4.24}$$

Ein Abgleich der errechneten Gierrate mit einem zu Testzwecken verbauten Gierratensensor weist einen geschwindigkeitsabhängigen Fehler auf. Daher wird die errechnete Gierrate mit einem identifizierten geschwindigkeitsabhängigen Korrekturwert $\dot{\psi}_{\text{Korr}} = (1 - \frac{v_{x_2}}{200})$ multipliziert. Auf diese Weise kann dem Problem des fehlenden Gierratensensors im Seriensattelauflieger begegnet werden.

Experimentell zugänglicher CAN Bus des Serienzugfahrzeugs nach SAE J1936

Die Bewegung des Sattelzugs wird maßgeblich durch das Antriebs- und Bremsmoment sowie den Lenkwinkel der gelenkten Vorderachse des Zugfahrzeugs eingeleitet und durch den Fahrer vorgegeben, allerdings sind dem Seriensattelauflieger über den zuvor beschriebenen CAN Bus nach ISO 11992 hinaus keinerlei Informationen zugänglich. Lediglich im experimentellen Umfeld besteht die Möglichkeit bei ausgewählten Zugfahrzeugen den fahrzeugspezifischen CAN Bus auszulesen. Das Netzprotokoll des Zugfahrzeug CAN Bus ist in der SAE J1939 spezifiziert [SAE18]. Innerhalb der vorliegenden Arbeit werden die Größen Lenkradwinkel δ_L und die Gierrate des Zugfahrzeugs $\dot{\psi}_1$ zur Systemmodellierung, Parameteridentifikation und Validierung verwendet. Die entwickelten Algorithmen sind zur Berechnung der Zielgrößen jedoch nicht auf Informationen des Zugfahrzeug CAN Bus angewiesen. Dadurch ist ein vom Zugfahrzeug unabhängiger Einsatz möglich.

Experimentell eingesetzte Zusatzsensorik und Prototypingmodul

Neben den zuvor beschriebenen serienmäßig verbauten Signalquellen kommen im Versuchsträger weitere Sensoren zum Einsatz. Zur Messung des Knickwinkels θ zwischen Zugfahrzeug und Sattelauflieger wird ein Winkelsensor von V.S.E. Vehicle Systems Engineering B.V. in den Königszapfen integriert. Darüber hinaus werden die Reifenquerkräfte an der ersten Sattelaufliegerachse $F_{y_{21},l}$ und $F_{y_{21},r}$ indirekt über an der Achse angebrachte Dehnungsmessstreifen (DMS) gemessen. Die DMS werden vom Fahrversuch der BPW Bergische Achsen KG verbaut und kalibriert, sowie entsprechend der firmeninternen Produktqualitätsstandards validiert. Spezielle Fahrversuche mit zusätzlicher Messung der Reifenquerkräfte mit Messrädern der Firma Kistler bestätigen die Qualität der Messung. Für das Einspurmodell wird als resultierende Kraft des einzelnen Ersatzreifens der Achse eine Addition der Reifenquerkräfte links und rechts angenommen. Auch die experimentelle Zusatzsensorik wird lediglich zur Systemmodellierung, Parameteridentifikation und Validierung, aber nicht innerhalb der resultierenden Algorithmen verwendet.

Zur echtzeitfähigen prototypischen Umsetzung der entwickelten Algorithmen wird ein ETAS ES 910 Prototyping- und Schnittstellenmodul eingesetzt, welches über einen experimentellen CAN Bus mit dem DEWESoft SIRIUS Datenerfassungssystem kommuniziert. Es ermöglicht eine einfache und schnelle Integration der auf einem Entwicklungsrechner erarbeiteten Methoden in den Versuchsträger, wodurch sich Testfahrten unter realen Bedingungen im Versuchsfahrzeug umsetzten lassen. Das Prototypingmodul ist grundsätzlich gegen eine andere Hardware austauschbar, wobei besonders in Hinblick auf eine potenzielle Serienanwendung der Zielkonflikt zwischen Kosten und Rechenperformanz getroffen werden muss.

Mit dem in diesem Abschnitt beschriebenen Versuchsträger lassen sich sowohl im öffentlichen Straßenverkehr als auch auf ausgewählten Teststrecken Versuchsfahrten durchführen, um Messdaten zur Modellierung und Parameteridentifikation zu generieren und darüber hinaus die entwickelten Algorithmen im realen Umfeld zu testen. Der gesamte beschriebene Aufbau ist in Bild 4.5 dargestellt.



Bild 4.5: Experimenteller Aufbau des Versuchsfahrzeugs: Im Datenerfassungssystem von DEWESoft laufen alle Informationen zusammen, die CAN Bus Verbindungen sind in orange und die analogen Sensoranschlüsse sind in blau dargestellt. Die Abbildung des Sattelzuges ist an [BPW21] angelehnt.

4.2.2 Parametrierungsablauf

Zugfahrzeuge verschiedener Hersteller unterscheiden sich bezogen auf die Gesamtmasse und die Maße durch die gesetzlichen Regulierungen nur marginal. Darüber hinaus ist ein bestimmtes Zugfahrzeug vergleichsweise geringeren Schwankungen der Gesamtmasse und des Fahrzeugschwerpunktes ausgesetzt, welche maßgeblich auf die Anzahl der Insassen und deren mitgeführte Gegenstände sowie den Tankinhalt zurückzuführen sind. Je nach Fahrzeugausstattung beträgt die Massenänderung ungefähr 10-15 % der Leermasse und wird in dieser Arbeit als vernachlässigbar klein angenommen. Die verwendeten Parameter wurden durch Messungen und aus Datenblättern ermittelt und sind in Tabelle 4.3 zusammengefasst.

Anders verhält es sich mit dem Sattelauflieger. Dieser kann mit unzähligen Beladungsvarianten betrieben werden, bei denen sich die Gesamtmasse und der Schwerpunkt des Fahrzeugs signifikant verändern. Im vollbeladenen Zustand beträgt die Gesamtmasse ungefähr das Vierfache der Leermasse und beeinflusst maßgeblich die Dynamik. Aus diesem Grund wird die Masse des Sattelaufliegers durch die bekannte Leermasse und die im experimentellen Umfeld bekannte Zuladung bestimmt. Das sich entsprechend der Zuladung ergebende Gierträgheitsmoment wird auf Grund der vereinfachten Annahme eines Quaders mit homogener Massenverteilung aus der Gesamtmasse des Sattelaufliegers und den Fahrzeugmaßen näherungsweise berechnet. Die Position des Schwerpunktes in Fahrzeuglängsrichtung ist nicht bekannt und ließe sich nur mit erhöhtem Vermessungsaufwand bestimmen. Aus diesem Grund wird sie für die jeweilige Beladung im Rahmen der nachfolgend erläuterten Parameteridentifikation bestimmt. Eine Übersicht zu den invarianten geometrischen Längen und Massen des Sattelaufliegers ist in Tabelle 4.3 gegeben. Die Abstände der Achsen und des Koppelpunktes beziehen sich auf die Rückwand des Sattelaufliegers, somit kann die Schwerpunktposition in Fahrzeuglängsrichtung $x_{SP_{RW}}$ ebenfalls bezogen auf die Rückwand

Parameter	Beschreibung	Wert	Einheit
m_1	Masse Zugfahrzeug	8.420	kg
J_1	Gierträgheitsmoment Zugfahrzeug	35.000	${ m kg}{ m m}^2$
a_1	Abstand Vorderachse-Schwerpunkt	1,175	m
b_1	Abstand Hinterachse-Schwerpunkt	2,535	m
h_1	Abstand Koppelpunkt-Schwerpunkt	1,935	m
m_2	Masse Sattelauflieger	7.500 + Zuladung	kg
J_2	Gierträgheitsmoment Sattelauflieger	$\frac{1}{2}m_2\left(\ell_{\mathrm{Spur}}^2+\ell_2^2\right)$	${ m kg}{ m m}^2$
$\ell_{ m Spur}$	Spurweite Sattelauflieger	2,165	m
ℓ_2	Gesamtlänge Sattelauflieger	13	m
$a_{2_{\mathrm{RW}}}$	Abstand Rückwand-Koppelpunkt	12	m
$b_{21_{\rm RW}}$	Abstand Rückwand-Achse 1	5,67	m
$b_{22_{\mathrm{RW}}}$	Abstand Rückwand-Achse 2	4,32	m
$b_{23_{\rm RW}}$	Abstand Rückwand-Achse 3	2,97	m



identifiziert werden, um daraus anschließend die schwerpunktbezogenen Längen aus Bild 4.3 zu berechnen.

Neben der ladungsabhängigen Position des Schwerpunkts in Fahrzeuglängsrichtung ist insbesondere die Bestimmung der Reifenparameter der Gleichungen (4.3) - (4.7) nicht trivial. Für die direkte Vermessung der Reifenquerkräfte in Abhängigkeit vom Schräglaufwinkel, um daraus die Reifenparameter zu bestimmen, sind kostenintensive Prüfstände und Sensorik notwendig. Eine Alternative ist die Identifikation dieser Parameter innerhalb des Gesamtfahrzeugmodells auf Basis von experimentellen Messdaten. Für die Parameter der Reifen werden folgende Annahmen getroffen:

- Der maximale Reibwert μ_{\max} ist für alle Achsen gleich,
- die Reifenparameter der drei Sattelaufliegerachsen sind identisch,
- die Reifenparameter der Achsen im Zugfahrzeug unterscheiden sich aufgrund unterschiedlicher Aufhängungen untereinander und von den Sattelaufliegerachsen.

Der maximale Reibwert ist stark von den Witterungsbedingungen, dem Fahrbahnuntergrund und den Reifen sowie deren Zustand abhängig und variiert somit fortlaufend. Innerhalb dieser Arbeit wird lediglich ein ausgewählter Reifensatz betrachtet und die Bedingungen sind homogen zu trockenem Asphalt gewählt. Umfangreiche Untersuchungen zur echtzeitfähigen Schätzung des Reibwerts im PKW sind beispielsweise in [Wie20] beschrieben. Die letzte Annahme wird dadurch begründet, dass hinsichtlich eines geringen Rechenaufwands die Radaufhängungen im Modell der Sattelzugquerdynamik in Abschnitt 4.1 keine detaillierte Betrachtung finden, jedoch einen erheblichen Einfluss auf die auf den Aufbau wirkenden Reifenquerkräfte haben. Dieser Einfluss, der je nach Radaufhängung variiert, wird innerhalb des echtzeitfähigen Modells durch verschiedene Parameter des Reifenmodells für die unterschiedlichen Achsen berücksichtigt. Daher könnte das Reifenmodell innerhalb des vorgestellten vereinfachten Einspurmodells auch als Achsmodell bezeichnet werden. Die im Rahmen der Identifikation zu bestimmenden Parameter werden durch eine als konstant angenommene Lenkübersetzung i_{Lenk} komplettiert, die nicht bekannt ist und zur Umrechnung des gemessenen Lenkradwinkels in den Lenkwinkel δ notwendig ist. Eine Übersicht aller zu identifizierenden Parameter ist in Tabelle 4.4 gegeben.

Parameter	Beschreibung	Einheit	untere Grenze	obere Grenze
$\mu_{ m max}$	max. Reibwert für alle Achsen	-	0.1	1.2
<i>C</i> ₁₁	MFTM Vorderachse Zugfahrzeug	-	0.5	4
C_{12}	MFTM Hinterachse Zugfahrzeug	-	0.5	4
C_2	MFTM Sattelauflieger	-	0.5	4
$c_{1_{11}}$	MFTM Vorderachse Zugfahrzeug	-	$1 \cdot 10^{-1}$	$1 \cdot 10^{9}$
$c_{1_{12}}$	MFTM Hinterachse Zugfahrzeug	-	$1 \cdot 10^{-1}$	$1\cdot 10^9$
c_{2_2}	MFTM Sattelauflieger	-	$1 \cdot 10^{-1}$	$1\cdot 10^9$
<i>c</i> ₂₁₁	MFTM Vorderachse Zugfahrzeug	-	$1 \cdot 10^{-1}$	$1\cdot 10^9$
$c_{2_{12}}$	MFTM Hinterachse Zugfahrzeug	-	$1 \cdot 10^{-1}$	$1\cdot 10^9$
c_{2_2}	MFTM Sattelauflieger	-	$1 \cdot 10^{-1}$	$1\cdot 10^6$
$\ell_{ m R_{11}}$	Einlauflänge Zugfahrzeug vorne	m	0.01	2
$\ell_{ m R_{12}}$	Einlauflänge Zugfahrzeug hinten	m	0.01	2
$\ell_{ m R_2}$	Einlauflänge Sattelauflieger	m	0.01	2
$x_{\rm SP_{RW}}$	Abstand Rückwand-Schwerpunkt	m	4	12
$i_{ m Lenk}$	Lenkübersetzung	-	15	30

Tabelle 4.4: Parameter des Sattelzugs, welche im Rahmen der Parameteridentifikation auf Basis von Messda-
ten bestimmt werden. Zusätzlich sind die oberen und unteren Grenzen der jeweiligen Parameter
gegeben, welche den Lösungsraum innerhalb des Optimierungsalgorithmus einschränken.

Zur Identifikation der nicht direkt Messbaren oder aus Datenblättern bestimmbaren Parameter werden zunächst ausgewählte Manöver mit dem Versuchsträger durchgeführt. Bei der Auswahl der Manöver ist darauf zu achten, dass die zu identifizierenden Parameter während der Versuchsdurchführung ausreichend angeregt werden. Da es sich um ein reines Querdynamikmodell handelt, werden für die Parameteridentifikation folgende querdynamische Manöver abgefahren:

- Lenkwinkelsinus mit unterschiedlichen Amplituden, Frequenzen und Geschwindigkeiten,
- Lenkwinkelsprünge mit unterschiedlichen Amplituden und Geschwindigkeiten,
- Kreisfahrten mit unterschiedlichen Radien und Geschwindigkeiten.

Um den Einfluss unterschiedlicher Beladungen des Sattelaufliegers zu berücksichtigen, werden zwei verschiedene Beladungszustände betrachtet: Leer und teilbeladen mit einer Sattelaufliegergesamtmasse von 24.000 kg. Der dabei entstandene Datensatz wird anschließend zur Identifikation der Modellparameter mittels eines Optimierungsalgorithmus verwendet. Dazu wird ein Kostenfunktional C_{Ident} benötigt, welches die Abweichung des Modellausgangs

$$\boldsymbol{Y}_{\text{Ident}} = \begin{pmatrix} \dot{\psi}_{1_{1}} & \cdots & \dot{\psi}_{1_{n_{k}}} \\ \dot{\psi}_{2_{1}} & \cdots & \dot{\psi}_{2_{n_{k}}} \\ \theta_{1} & \cdots & \theta_{n_{k}} \\ F_{y_{21_{1}}} & \cdots & F_{y_{21_{n_{k}}}} \end{pmatrix}$$
(4.25)

über alle n_k Zeitschritte von den im Experiment tatsächlich im Versuchsfahrzeug gemessenen Größen $\boldsymbol{Y}_{\text{Ident}}^{\text{Exp}}$ quantifiziert. Als bezüglich der in \boldsymbol{p} zusammengefassten Parameter zu minimierendes Kostenfunktional

$$\min_{\boldsymbol{p}} C_{\text{Ident}}(\boldsymbol{p}) = \min_{\boldsymbol{p}} \sum_{i=1}^{n_{\text{Ident}}} \frac{\left\| \left(\boldsymbol{Y}_{\text{Ident},i}^{\text{Exp}} - \boldsymbol{Y}_{\text{Ident},i} \right) \right\|_{2}}{\left\| \left(\boldsymbol{Y}_{\text{Ident},i}^{\text{Exp}} - \overline{\boldsymbol{Y}}_{\text{Ident},i}^{\text{Exp}} \right) \right\|_{2}}$$
(4.26)

wird die über die $n_{\text{Ident}} = 4$ Messgrößen aufsummierte normierte euklidische Norm verwendet, wobei $\overline{Y}_{\text{Ident},i}^{\text{Exp}}$ der Mittelwert der Referenzmessung ist. Die Normierung ist für eine gleichmäßige Gewichtung der heterogenen Messgrößen innerhalb des Optimierungsverfahrens erforderlich. Zur Minimierung des Kostenfunktionals und der damit einhergehenden Bestimmung des auf den Identifikationsdatensatz optimierten Parametersatzes p_{opt} gilt es ein nichtlineares Optimierungsproblem zu lösen. Dafür kommen diverse Optimierungsalgorithmen in Frage, eine Übersicht wird in [HG10] vorgestellt.

Zur Identifikation der Modellparameter wird die Partikelschwarmoptimierung (PSO) ausgewählt, welche ursprünglich in [KE95] vorgestellt wird. Dabei handelt es sich um einen globalen Optimierungsalgorithmus, welcher sich am Vorbild von Tierschwärmen bei der Futtersuche orientiert. Eine bestimmte Anzahl an Partikeln n_{Partikel} , welche sinnbildlich für die Anzahl an Individuen eines Tierschwarms stehen, werden zufällig oder nach einem bestimmten Muster innerhalb des Lösungsraums an initialen Positionen $p_{j=0,i}$ verteilt und mit einem initialen Geschwindigkeitsvektor $v_{j=0,i}$ versehen. Daraufhin wird das zu optimierende Kostenfunktional für jedes Partikel ausgewertet und basierend auf den Ergebnissen die Geschwindigkeitsvektoren $v_{j,i}$ nach einer vorgegebenen Struktur des Informationsaustausches aller Partikel angepasst. Der Wert des Kostenfunktionals für ein Partikel entspricht in Analogie zu Tierschwärmen der Beurteilung der aktuellen Position eines Individuums hinsichtlich der Eignung zur Futterbeschaffung, die Struktur des Informationsaustausches entspricht der Kommunikation unter den Individuen. Unter Einbeziehung der Modifikationen der ursprünglichen PSO nach [MC11], [Ped10] berechnet sich die iterative Anpassung des Geschwindigkeitsvektors und die sich daraus ergebenden neuen Partikelposition im Iterationsschritt j + 1 ($j = 0, ..., n_{\text{Iter,PSO}}$) zu

$$\boldsymbol{v}_{j+1,i} = \gamma_0 \boldsymbol{v}_{j,i} + \gamma_1 \eta_1 \left(\boldsymbol{p}_{j,i}^{\text{best}} - \boldsymbol{p}_{j,i} \right) + \gamma_2 \eta_2 \left(\boldsymbol{g}_j^{\text{best}} - \boldsymbol{p}_{j,i} \right), \qquad (4.27)$$

$$p_{j+1,i} = p_{j,i} + v_{j+1,i}.$$
 (4.28)

Der neue Geschwindigkeitsvektor setzt sich aus einer gewichteten Summe über den vorhergegangenen Geschwindigkeitsvektor, die beste individuelle Position p^{best} und die beste globale Position g^{best} zusammen. Die Gewichte lassen sich als Trägheit der eigenen Bewegung γ_0 , kognitiver Gewichtungsfaktor γ_1 und sozialer Gewichtungsfaktor γ_2 bezeichnen. Zusätzlich wird in jeder Iteration der kognitive und soziale Faktor mit im Intervall [0,1] gleichverteilten Zufallsfaktoren η_1 und η_2 multipliziert. Die Iterationen werden solange durchgeführt, bis ein zuvor festgelegtes Abbruchkriterium erfüllt wird und die globale beste Lösung g^{best} wird als Ergebnis ausgegeben. Die Einstellungen der PSO sind der Tabelle 4.5 zu entnehmen.

Parameter/Teilvorgang	Beschreibung	Wert/Wertebereich
Initialisierung der Partikel	gleichverteilt	Parametergrenzen (s. Tabelle 4.4)
γ_1	fest	1,49
γ_2	fest	1,49
$n_{ m Partikel}$	fest	240
$n_{ m Iter,PSO}$	fest	200
Abbruchkriterium	Iteration $n_{\text{Iter,PSO}}$ erreicht	-

 Tabelle 4.5: Einstellungen der PSO zur Identifikation der unbekannten Parameter des Sattelzugquerdynamikmodells

Aufgrund ungünstiger Einstellungen der PSO in Kombination mit den stochastischen Eigenschaften des Algorithmus kann eine ungewünschte Konvergenz gegen ein lokales Minimum auftreten. Um die Eignung der PSO mit den gewählten Einstellungen für das vorliegende Optimierungsproblem und die statistische Signifikanz des Ergebnisses beurteilen zu können, wird die PSO 100 Mal durchgeführt. Bild 4.6 stellt die Ergebnisse in Form von Histogrammen dar, die Wertebereiche der horizontalen Achsen entsprechen dem vorgegebenen Suchraum, beschrieben durch die Grenzen in Tabelle 4.4. Die Lenkübersetzung i_{Lenk} sowie die Position des Schwerpunkts für die betrachteten Beladungszustände $x_{SP_{RW}}$ lassen sich eindeutig bestimmen. Für die Lenkübersetzung ergibt sich



Bild 4.6: Histogramme zur Häufigkeit der identifizierten Parameter über 100 Optimierungsdurchläufe mit der PSO. Der Wertebereich der horizontalen Achsen ist auf die für die PSO vorgegebene obere und untere Grenze des jeweiligen Parameters limitiert. Der optimale Parametersatz ist in grün markiert, der schlechteste in rot.

ein Wert von ungefähr 1:23, welcher in den in der Literatur angegebenen Bereich für die Lenkübersetzung von Fernverkehrs-LKW fällt [Hil16]. Der Schwerpunkt des teilbeladenen Fahrzeugs wird im Vergleich zum leeren Sattelauflieger etwas weiter vorne identifiziert, was aufgrund der frontlastigen Zuladung zu erwarten ist. Die physikalische Interpretierbarkeit ist hingegen etwas in Frage zu stellen, da grobe Berechnungen den Schwerpunkt etwas weiter hinten vermuten lassen. Dies kann auf die vereinfachten Annahmen innerhalb des Einspurmodells, beispielsweise die Annahme eines Quaders mit homogener Massenverteilung zur Berechnung des Gierträgheitsmoments, zurückzuführen sein und ist im Rahmen weiterführender Untersuchungen zu beachten. Als problematischer hinsichtlich ihrer Identifikation stellen sich die reifenbezogenen Parameter heraus. Während die Identifikation der Einlauflängen $\ell_{R_{ji}}$ über die 100 Durchläufe in einem eindeutigen Bereich resultiert, streuen die übrigen Parameter relativ stark über den gesamten Suchraum und laufen zum Teil auch in die Suchraumgrenzen. Dies ist möglicherweise auf Korrelationen unter den Parametern oder nicht ausreichende Sensitivität der Parameter innerhalb des Identifikationsdatensatzes zurückzuführen. Die genauen Ursachen und mögliche Lösungsansätze werden im Rahmen dieser Arbeit nicht weiter erforscht, da diese Parameter ohnehin nicht direkt physikalisch Interpretierbar sind und für die Anwendungszwecke in dieser Arbeit lediglich das Ein-/Ausgangsverhalten des Reifenmodells von Relevanz ist. Der Bereich, in dem der maximale Reibwert μ_{max} identifiziert wird, liegt in etwa zwischen 0,6 und 0,8 und resultiert somit in Ergebnissen, die mit anderen Vorarbeiten vergleichbar sind [LG04], [Leh15], [Tun21]. Die Häufung bei 0,6 lässt sich durch eine leicht feuchte Fahrbahn bei der Aufnahme der Messdaten erklären.

Der optimale Parametersatz p_{opt} ist in grün markiert und liegt meistens im Bereich der am häufigsten auftretenden Ergebnisse. Für keinen der optimalen Parameter wird eine der Suchraumgrenze als Lösung ausgewählt, was für eine sinnvolle Auswahl der Suchraumeinschränkung spricht. Interessant ist darüber hinaus, dass die schlechteste, in rot markierte Lösung für mehrere Parameter der Suchraumbegrenzung entspricht. Der Optimierungsalgorithmus konvergiert demnach nicht bei jedem Durchlauf gegen das beste bekannte und somit mutmaßlich globale Optimum, was sich auch in den Verläufen des Kostenfunktionals über die Iterationsschritte der PSO in Bild 4.7 zeigt. Eine Erhöhung der Partikelanzahl $n_{Partikel}$ könnte zu einer leichten Verbesserung der Ergebnisse aus den Einzeldurchläufen führen, erhöht jedoch auch den dafür notwendigen Rechenaufwand. Da das schlechteste Ergebnis weniger als 5 % vom besten abweicht, scheint bei der gewählten Parametrierung eine ausreichende Konvergenz aufzutreten. Grundsätzlich ist festzuhalten, dass sich eine plausible Einstellung finden lässt, welche für die Methoden in dieser Arbeit geeignet ist.

Im weiteren Verlauf der Arbeit wird sowohl im Rahmen der Simulation als auch im Rahmen der experimentellen modellbasierten Zustandsschätzung der in diesem Abschnitt ermittelte optimale Parametersatz p_{opt} verwendet, außer es wird explizit eine Abweichung davon beschrieben. Die Qualität des Querdynamikmodells für den Sattelzug mit der gewählten Parametrierung wird im folgenden Abschnitt durch experimentelle Validierung eruiert.

4.3 Experimentelle Validierung des Querdynamikmodells für den Sattelzug

Die Qualität der modellbasierten Zustandsschätzung und die Aussagekraft von Voruntersuchungen in Simulationen ist in hohem Maße von der Modellgüte abhängig. Das im Abschnitt 4.1 hergeleitete und nach den Ausführungen aus Abschnitt 4.2 parametrierte Modell wird in diesem Abschnitt anhand experimenteller Messfahrten mit dem Versuchsträger aus Abschnitt 4.2.1 validiert. Die dafür verwendeten Messdaten haben zum Ziel, den Arbeitsraum eines Serienfahrzeugs abzubilden, um die Aussagekraft des Modells für diesen relevanten Bereich beurteilen zu können. Dabei werden


Bild 4.7: Verläufe des Kostenfunktionals über 100 Optimierungsdurchläufe mit der PSO. Der Optimierungsdurchlauf, der zum optimalen Parametersatz p_{opt} führt, ist in grün dargestellt. Der Durchlauf, der zum schlechtesten Wert des Kostenfunktionals führt, ist in rot zu sehen.

ausschließlich Fahrsituationen in Betracht gezogen, in denen das Fahrzeug ein stabiles Fahrverhalten aufweist. Dies ist im Serienbetrieb überwiegend der Fall. Die Aussagekraft des Modells in instabilen Fahrsituationen, beispielsweise beim sogenannten *jackknifing* (angelehnt an das englische Wort für Klappmesser, Einknicken des Anhängers relativ zum Zugfahrzeug), beim Driften oder in extremen Kurvenfahrten mit Tendenz zum Kippen, kann demnach nicht beurteilt werden. Dafür wäre das Einfahren von Messdaten besonders sicherheitskritischer Fahrmanöver notwendig, was nur unter entsprechenden Vorkehrungen, z.B. Einsatz von Stützrädern zur Vermeidung übermäßiger Rollwinkel, durchführbar ist.

Zur möglichst ganzheitlichen Validierung wird mit dem leeren und dem teilbeladenen Sattelauflieger eine zufällige Abfolge von Manövern unter Berücksichtigung der zuvor genannten Anforderungen gefahren und anschließend das Simulationsergebnis mit den Messdaten verglichen. In Bild 4.8 ist der Verlauf der Eingangsgrößen (Lenkradwinkel δ_L und Längsgeschwindigkeit v_{x_2}), der Messgrößen und der korrespondierenden simulierten Zustandsgrößen für den leeren Sattelauflieger über der Zeit dargestellt. Dabei wird nahezu der gesamte üblicherweise im Serienbetrieb vorliegende Geschwindigkeitsbereich bis zu 80 km h^{-1} durchfahren und der Lenkradwinkel über ein weites Spektrum an Frequenzen und Amplituden variiert. Die simulierten Gierraten und der Knickwinkel zeigen durchweg einen gute Übereinstimmung mit der Messung. Die mittlere Abweichung beträgt für die Gierrate des Zugfahrzeuges $1,38 \circ \text{s}^{-1}$, für die des Sattelaufliegers $0,81 \circ \text{s}^{-1}$. Die maximalen Abweichungen von bis zu $7,24 \circ \text{s}^{-1}$ und $4,03 \circ \text{s}^{-1}$ treten im Bereich der höchsten Gierraten zwischen t = 50 und t = 70 s auf. Der Knickwinkel weist eine mittleren und maximale Abweichung von $0,65^{\circ}$ respektive 2° auf. Der Vergleich der gemessenen und der simulierten Reifenquerkräfte



Bild 4.8: Validierung der Simulation mit ausgewähltem Parametersatz p_{opt} anhand experimenteller Messdaten einer zufälligen Abfolge mehrere Manöver für den leeren Sattelauflieger mit einer Gesamtmasse von $m_2 = 7.500$ kg.

fällt aufgrund des deutlichen Sensorrauschens etwas schwieriger. Gesamtheitlich kann eine richtige Tendenz und Größenordnung beobachtet werden, im Detail sind teilweise erhebliche Differenzen zu erkennen. Dies ist besonders bei ungefähr t = 80 s der Fall. Der Sattelzug vollführt eine enges Wendemanöver bei dem die Reifen der ersten und dritten Sattelaufliegerachse besonders beansprucht werden und auch visuell durch erkennbare elastische Verformung der Reifen und teilweise abfallende Kautschukteile deutlich wird. Dabei tritt die maximale Abweichung von 5,97 kN auf, während die mittlere Abweichung 0,94 kN beträgt. Für eine bessere zeitlichen Auflösung ist das höherfrequente Manöver am Ende der Messung vergrößert dargestellt.

In Bild 4.9 sind die Validierungsergebnisse für den teilbeladenen Sattelauflieger zu sehen. Die Abfolge der Manöver unterscheidet sich von denen des unbeladenen Sattelaufliegers, deckt aber im Wesentlichen den gleichen Bereich an Geschwindigkeiten, Lenkradwinkelfrequenzen und -amplituden ab. Deutlich zu erkennen sind die aufgrund der zusätzlichen Beladung größeren auftretenden Reifenquerkräfte, die im Maximum ungefähr doppelt so groß sind wie für das unbeladene Fahrzeug. Die größte Abweichung von $9,57 \,\mathrm{kN}$ tritt im höherfrequenten Bereich, die mittlere Abweichung liegt bei $1,43 \,\mathrm{kN}$. Grundsätzlich scheint die Simulation die Reifenquerkräft bei niedrigen Reifenquerkräften mit zügiger Lenkradwinkeländerung zu unterschätzen. Ganzheitlich betrachtet ist aber auch im teilbeladenen Zustand eine qualitative Simulation der Reifenquerkräft der ersten Sattelaufliegerachse erzielt worden. Werden darüber hinaus die Reifenquerkräfte $F_{y_{22}}$ und $F_{y_{23}}$ betrachtet, erscheinen diese in ihrer Frequenz und Amplitude durchaus plausibel. Eine experimentelle Validierung kann aufgrund fehlender Sensorik jedoch nicht durchgeführt werden. Die Gierraten und der Knickwinkel weisen eine ähnliche Güte wie im teilbeladenen Zustand auf.

	$m_2=7.500\mathrm{kg}$		$m_2 = 24.000\mathrm{kg}$	
Mess- / Zustandsgröße	RMSE	max. Abweichung	RMSE	max. Abweichung
Gierrate Zugfahrzeug ψ_1	$1,38 {}^{\circ}{ m s}^{-1}$	$7,24 {}^{\circ}{ m s}^{-1}$	$1,51 {}^{\circ}{ m s}^{-1}$	$7,11 {}^{\circ}{ m s}^{-1}$
Gierrate Sattelauflieger ψ_2	$0,81 {}^{\circ}{ m s}^{-1}$	$4,03 {}^{\circ}{\rm s}^{-1}$	$0,84 {}^{\circ}{ m s}^{-1}$	$2,79 {}^{\circ}{\rm s}^{-1}$
Knickwinkel θ	$0,\!65^{\circ}$	2°	$0,\!64^{\circ}$	$2,\!11^{\circ}$
Reifenquerkraft $F_{y_{21}}$	$0,94\mathrm{kN}$	$5{,}97\mathrm{kN}$	$1,\!43\mathrm{kN}$	$9,57\mathrm{kN}$

Die Tabelle 4.6 fasst die beschriebenen Fehlermaße zusammen.

Tabelle 4.6: Zusammenfassung der Fehlermaße für die Validierungsmanöver

4.4 Fazit

In diesem Kapitel wurde die Herleitung des physikalischen Querdynamikmodells des Sattelzugs beschrieben, welches im weiteren Verlauf der Arbeit zur Untersuchung der zu vergleichenden Ansätze der modellbasierten und datenbasierten Zustandsschätzung in Simulation verwendet wird. Darüber hinaus findet das Modell ebenfalls Eingang in die experimentelle modellbasierte Zustandsschätzung.

Zu Beginn dieses Kapitels wurden für eine eindeutige Verortung der auftretenden Größen Koordinatensysteme nach DIN ISO 8855 definiert. Anschließend erfolgte eine auf publizierten wissenschaftlichen Erkenntnissen basierte Begründung zur Wahl einer geeigneten Modellierungstiefe.



Bild 4.9: Validierung der Simulation mit ausgewähltem Parametersatz p_{opt} anhand experimenteller Messdaten einer zufälligen Abfolge mehrere Manöver für den teilbeladenen Sattelauflieger mit einer Gesamtmasse von $m_2 = 24.000$ kg.

Dabei zielte die Wahl auf eine annehmbare Lösung des Konflikts zwischen Genauigkeit und Rechenaufwand ab. Die Entscheidung ist auf ein nichtlineares Einspurmodell gefallen, welches in der Lage ist, die im Serienbetrieb auftretenden Fahrzustände im Hinblick auf die Zielgrößen dieser Arbeit mit ausreichender Genauigkeit abzubilden.

Das resultierende Querdynamikmodell wurde durch entsprechende Parametrierung an den betrachteten Versuchsträger angepasst. Dabei sind nicht direkt messbare oder aus Datenblättern bekannte Parameter mit Hilfe einer PSO auf Grundlage von Messdaten des Versuchsträgers identifiziert worden. Grundsätzlich erweist sich die Identifikation durch die PSO als probates Vorgehen, jedoch lassen sich nicht alle Parameter eindeutig identifizieren. Dies ist möglicherweise auf Korrelationen unter den Parametern, nicht ausreichende Anregung ebendieser oder die nicht garantierte Konvergenz der PSO gegen das globale Optimum zurückzuführen und gilt es in weiterführenden Untersuchungen zu eruieren. Darüber hinaus ist bei einer physikalischen Interpretation der Parameter zu beachten, dass durch die vereinfachenden Modellannahmen Abweichungen im Vergleich zu den tatsächlichen Parametern im realen Fahrzeug auftreten können. Die abschließende experimentelle Validierung bekräftigt die Eignung des Modells für den weiteren Einsatz innerhalb dieser Arbeit.

5 Simulative Untersuchungen zur Zustandsschätzung im Nutzfahrzeug

Das zuvor vorgestellte Simulationsmodell der Sattelzugquerdynamik wird in diesem Kapitel dazu verwendet, die in ihren Grundzügen vorgestellten modellbasierten Methoden aus Kapitel 2 und den datenbasierten Ansatz aus Kapitel 3 konkret auf die vorliegende Problemstellung anzuwenden und zu vergleichen. Es ersetzt im Vergleich zu einem experimentellen Ansatz das reale Fahrzeug als zugrundeliegendes System. Die Vorteile gegenüber einer experimentellen Untersuchung bestehen darin, dass in der Simulation jegliche Bedingungen und Einflüsse, wie beispielsweise die Systemparameter, das Prozessrauschen, das Messrauschen oder Umgebungseinflüsse wie veränderlicher Reibwert oder Fahrbahnneigung, exakt bekannt sind. Somit kann der Einfluss verschiedener Größen auf die Zustandsschätzung innerhalb der untersuchten Methoden isoliert betrachtet und bewertet werden. Die Übertragbarkeit der Erkenntnisse auf das reale System ist von der Modellgüte abhängig. Für eine Vergleichbarkeit der Methoden im Bezug auf das Simulationsmodell ist die Modellgüte allerdings nebensächlich, liefert aber dennoch keine allgemeingültigen Aussagen, die sich auf beliebige Systeme übertragen ließen.



Bild 5.1: Überblick zum Vorgehen in Kapitel 5

Bild 5.1 illustriert den Inhalt dieses Kapitels in allgemeiner Form. Das Simulationsmodell wird mit den Simulationsparametern p_{Sim} und den Rauschvarianzen für das Gauß'sche Prozessrauschen Q_{Sim} sowie Messrauschen R_{Sim} parametriert und unter Einfluss der Modelleingänge u simuliert. Dabei werden die Messgrößen und die bekannten Modelleingänge u_b abgegriffen und finden Eingang in die verschiedenen Methoden zur Zustandsschätzung. Für eine möglichst korrekte Übertragbarkeit der simulativen Ergebnisse auf das reale Fahrzeug wird das Modell entsprechend der gemessenen und identifizierten Parameter p_{opt} aus Abschnitt 4.2 mit p_{Sim} parametriert. Für die Simulation sind darüber hinaus die Rauschvarianzen festzulegen. Im weiteren Verlauf der Arbeit werden die Methoden auch anhand eines realen Sattelzugs untersucht. Die dabei eingestellten Rauschvarianzen, vgl. Abschnitt 6.1, werden für die simulativen Untersuchungen übernommen.

Die Entwicklung der modellbasierten Zustandsschätzung wird in Abschnitt 5.1 erläutert. Hierbei wird zunächst von einer optimalen Einstellung der Filter ausgegangen, d.h. das Systemmodell innerhalb der Filter mit dessen Parametern $p_{\text{Filt}} = p_{\text{Sim}}$ und die Rauschvarianzen $Q_{\text{Filt}} = Q_{\text{Sim}}$ sowie $R_{\text{Filt}} = R_{\text{Sim}}$ werden als exakt bekannt angenommen. Darüber hinaus wird die Analyse der Beobachtbarkeit des Systems vorgenommen. In Abschnitt 5.2 wird die Entwicklung des datenbasierten Ansatzes erläutert, welche in dieser Form am Beispiel eines PKWs in [ZBW21] veröffentlicht wurde. Dabei wird das Simulationsmodell zur Erstellung simulativer Trainingsdaten mit Trainingseingangsgrößen verwendet, wobei Parametrierung und Rauschen zunächst im Trainingsund im Testfall unverändert bleiben. Die Eingangsgrößen im Testfall sind allerdings nicht als Untermenge innerhalb der Trainingsdaten enthalten. Die simulativen Ergebnisse und ein Vergleich der Methoden unter den beschriebenen idealen Bedingungen werden in Abschnitt 5.3 dargestellt. In einer Serienanwendung lägen diese idealisierten Bedingungen mit großer Wahrscheinlichkeit nicht vor. Daher werden anschließend im Abschnitt 5.4 ausgewählte Größen bewusst manipuliert, um deren Einfluss auf das Schätzergebnis zu untersuchen. Abschließend wird in Abschnitt 5.5 ein Fazit aus den Erkenntnissen gezogen.

5.1 Modellbasierte Zustandsschätzung in der Simulation

Auf Grundlage der theoretischen Ausführungen zum EKF in Abschnitt 2.3.1 und zum UKF in Abschnitt 2.3.2 werden in diesem Abschnitt die konkrete Anwendung und die Einstellungen der Filter beschrieben. In der Simulation gestaltet sich dieser Ablauf relativ simpel, da wie in der Einleitung des Kapitels beschrieben die wahren Werte aller Größen exakt bekannt sind. Wegen der zuvor beschriebenen besonderen Gegebenheiten (siehe Abschnitt 4.2.1), sind im realen Sattelzug nicht alle Eingangsgrößen des Modells bekannt. So ist es erforderlich, den Lenkwinkel des Zugfahrzeugs δ entsprechend der Ausführungen in Abschnitt 2.4 mitzuschätzen. Der erweiterte Zustandsvektor für die Zustandsschätzung inklusive der Schätzung des unbekannten Eingangs ergibt sich zu

$$\hat{\boldsymbol{x}} = \left(\hat{v}_{y_1}, \hat{\psi}_1, \hat{v}_{y_2}, \hat{\psi}_2, \hat{\theta}, \hat{F}_{y_{11}}, \hat{F}_{y_{12}}, \hat{F}_{y_{21}}, \hat{F}_{y_{22}}, \hat{F}_{y_{23}}, \hat{\delta}\right)^{\mathrm{T}},$$
(5.1)

und enthält fortan 11 Zustände. Die im Serienfahrzeug zur Verfügung stehende Messgröße beschränkt sich auf die Gierrate des Sattelaufliegers

$$y = \psi_2. \tag{5.2}$$

Darüber hinaus wird den Filtern die bekannte Eingangsgröße der Längsgeschwindigkeit des Sattelaufliegers $u_{\rm b} = v_{x_2}$ zugeführt.

In Abschnitt 2.2 wird die Notwendigkeit der Beobachtbarkeit für eine erfolgreiche Zustandsschätzung beschrieben. Darin wird bei Systemen mit Parametern, die sich um mehrere Größenordnungen unterscheiden, auf die strukturelle Beobachtbarkeitsanalyse verwiesen. Im vorliegenden Fall der Nutzfahrzeugquerdynamik sorgen insbesondere die Parameter der Reifenmodelle, welche Reifenquerkräfte in Kilonewton darstellen, für numerische Probleme bei der Anwendung des Kalman-Kriteriums für das jeweils im Arbeitspunkt linearisierte System. Daher wird die strukturelle Beobachtbarkeit als notwendiges Kriterium der Beobachtbarkeit anhand des um den Lenkwinkel erweiterten Systems mit dem Zustandsvektor aus Gleichung (5.1) geprüft.

Die Ergebnisse werden zur Veranschaulichung anhand eines synthetischen Manövers in Bild 5.2 dargestellt. Das Manöver beginnt mit einer Geradeausfahrt gefolgt von einem Lenkwinkelsinus und schließt mit einer erneuten Geradeausfahrt. Die Längsgeschwindigkeit beträgt durchgehend konstant 10 m s^{-1} . Zu jedem diskreten Zeitpunkt des Manövers wird das System im aktuellen Arbeitspunkt linearisiert (vgl. Gleichungen (2.3-2.4)) und die zwei Kriterien der Ausgangsverbundenheit sowie des strukturellen Rangs für die strukturelle Beobachtbarkeit aus Abschnitt 2.2 geprüft. Es ist zu beobachten, dass bei einer reinen Geradeausfahrt keins der beiden Kriterien erfüllt ist. Eine genauere Analyse zeigt, dass der Zustand Knickwinkel θ nicht ausgangsverbunden ist. Erst bei einer querdynamischen Anregung wird das System strukturell beobachtbar, was sich in der Erfüllung beider Kriterien widerspiegelt. Nach Beendigung der Anregung werden mit einer Verzögerung von t = 2,39 s bzw. t = 1,57 s beide Kriterien verletzt, was auf transiente Ausgleichsvorgänge bis zum Erreichen des Zustands der reinen Geradeausfahrt zurückzuführen ist. Die umfangreiche Untersuchung weiterer Manöver lässt darauf schließen, dass ausschließlich die reine Geradeausfahrt einen nicht beobachtbaren Zustand darstellt. In der Simulation und in der praktischen Anwendung haben sich daraus keine nennenswerten Probleme ergeben.

Die Kovarianzen des Prozess- und des Messrauschens werden wie in Abschnitt 2.3 beschrieben als mittelwertfreie, unkorellierte Normalverteilungen simuliert und entsprechend in EKF und



Bild 5.2: Die strukturelle Beobachtbarkeit wird anhand eines beispielhaften synthetischen Manövers geprüft. Das Kriterium 1 zeigt die Anzahl ausgangsverbundener Zustände während des Manövers an, das Kriterium 2 den strukturellen Rang nach Gleichung (2.7).

UKF optimal eingestellt, wobei sich die Varianzen an den in der experimentellen Untersuchung eingestellten Werten innerhalb der Filter orientieren und sich zu

$$\boldsymbol{Q} = \boldsymbol{Q}_{\text{Sim}} = \text{diag}\left(10^{-10}, 10^{-10}, 5 \cdot 10^{-8}, 10^{-9}, 10^{-10}, 10^{3}, 10^{3}, 10^{3}, 10^{3}, 10^{3}, 10^{-5}\right)$$
(5.3)

und

$$\boldsymbol{R} = \boldsymbol{R}_{\rm Sim} = \left(10^{-4}\right) \tag{5.4}$$

ergeben. Der Übersichtlichkeit halber werden die Einheiten der einzelnen Einträge nicht dargestellt. Eine gesonderte Bedeutung kommt dem letzten Eintrag der Prozessrauschkovarianzmatrix Qzu. Während die anderen Einträge genau den Varianzen der in der Simulation aufgebrachten Rauschterme entsprechen, muss die Kovarianz des Lenkwinkels eingestellt werden. Innerhalb des Filters wird für den Lenkwinkel eine Zufallsbewegung angenommen, weil dem Lenkwinkel keine definierte Dynamik unterstellt werden kann. Daher ist die Kovarianz des Lenkwinkels auch als Dynamik der Eingangsschätzung zu interpretieren. Sie wird empirisch zu 10^{-5} gewählt. Die initiale Fehlerkovarianz P_0 wird gleich der Kovarianz des Prozessrauschens Q eingestellt, spielt Die bisher beschriebenen Einstellungen gelten sowohl für das EKF als auch für das UKF, darüber hinaus sind für das UKF weitere Parameter einzustellen, welche die Verteilung der Sigma-Punkte beeinflussen. Entsprechend der Ausführungen in [van04] werden diese Parameter zu

$$\alpha_{\rm UKF} = 1, \quad \beta_{\rm UKF} = 2 \quad \text{und} \quad \kappa_{\rm UKF} = 0 \tag{5.5}$$

gewählt. Die simulativen Ergebnisse der Zustands- und Eingangsschätzung unter den beschriebenen Bedingungen werden im Vergleich zum datenbasierten Ansatz in Abschnitt 5.3 präsentiert. Dementsprechend wird nachfolgend zunächst die Anwendung des datenbasierten Ansatzes in der Simulation beschrieben.

5.2 Datenbasierte Zustandsschätzung in der Simulation

Analog zur modellbasierten Zustandsschätzung wird in diesem Abschnitt auf Grundlage der theoretischen Ausführungen zur datenbasierten Zustandsschätzung in Kapitel 3 die Anwendung auf den Sattelauflieger in der Simulationsumgebung beschrieben. Dafür wird zunächst die Erstellung der simulativen Trainingsdaten erläutert. Darauf folgt die Auslegung und das Training des KNNs.

5.2.1 Erstellung simulativer Trainingsdaten

Für die Erstellung des simulativen Trainingsdatensatzes werden der Lenkwinkel δ und die Fahrzeuglängsgeschwindigkeit des Sattelaufliegers v_{x_2} von realen Messfahrten mit dem teilbeladenen Versuchsfahrzeug (Sattelaufliegermasse $m_2 = 24.000 \text{ kg}$) herangezogen und als Eingangsgrößen dem Simulationsmodell zugeführt, um damit simulativ die Zielgrößen des KNNs zu erzeugen. Die Menge der verwendeten Manöver beträgt insgesamt 25 Einzelmanöver und zielt auf eine möglichst vollkommene Abdeckung des serienmäßigen Arbeitsraums des Sattelzugs ab. Darunter sind sinusförmige Lenkwinkelverläufe mit verschiedenen Amplituden und Frequenzen bei Geschwindigkeiten von 3 bis 20 m s^{-1} , Kreisfahrten mit konstanter und zunehmender Geschwindigkeit und Lenkwinkelsprünge bei unterschiedlichen Geschwindigkeiten. Die Verwendung realer Eingangsgrößen bietet gegenüber der Alternative synthetisch erzeugter Eingangsgrößen den Vorteil, dass sie zweifelsfrei mit dem realen Versuchsfahrzeug durchführbar sind und zu stabiler und sicherheitsunkritischer Fahrdynamik führen. Darüber hinaus unterliegen die am realen Fahrzeug gemessenen Eingangsgrößen dem tatsächlich vorliegenden Rauschen. Als Netzeingänge i werden der Lenkwinkel δ und die Längsgeschwindigkeit des Sattelaufliegers v_{x_2} verwendet. Die Zielgrößen t setzen sich aus Knickwinkel θ und Reifenquerkraft der ersten Achse im Sattelauflieger $F_{y_{21}}$ zusammen. Vor dem Einsatz der Daten für das Training von KNN werden diese normalisiert, d.h. jedes Messsignal wird separat Bezogen auf den Minimal- und Maximalwert im Trainingsdatensatz

in den Bereich zwischen -1 und 1 transformiert. Dies führt zu einer verbesserten Konvergenz beim Training (vgl. Abschnitt 3.3).

Für einen fairen Vergleich zu den optimal eingestellten Filtern aus Abschnitt 5.1 ist es notwendig, den datenbasierten Ansatz unter möglichst optimalen, aber realitätsnahen Bedingungen zu entwickeln. Dazu wird das Simulationsmodell zur Erstellung der Trainingsdaten mit den gleichen Einstellungen für Prozess- und Messrauschen beaufschlagt, wie es die Filter und beim Vergleich der Ergebnisse der verschiedenen Ansätze auch das Simulationsmodell aufweisen (vgl. Gleichungen (5.3) und (5.4)). Auf Basis des simulativ erzeugten Trainingsdatensatzes wird im Folgenden die Netzauslegung und das Training erläutert.

5.2.2 Netzauslegung und Training

Wie bereits im Grundlagenteil (Abschnitt 3.4) beschrieben, gilt es für die konkrete Anwendung von KNN auf eine zugrundeliegende Problemstellung diverse Hyperparameter auszulegen. Zur Abschätzung der erforderlichen Zeitverzögerung des Eingangs $n_{\rm ID}$ und der Ausgangsrückführung $n_{\rm FD}$ eignet sich als Alternative zum empirischen Vorgehen, welches den notwendigen Rechenaufwand für das Training deutlich erhöhen würde, die Betrachtung der Lipschitz-Indizes nach [HA93]. In Bild 5.3 sind die Lipschitz-Indizes für die Zielgrößen Knickwinkel θ und Reifenquerkraft der ersten Achse im Sattelauflieger $F_{y_{21}}$ dargestellt, welche anhand drei zufällig gewählter Manöver berechnet werden. Die Reihenfolge, in der die Netzeingänge sukzessive hinzugefügt werden, orientiert sich an den Ausführungen in [Nel20] und beginnt mit den um einen Zeitschritt verzögerten Netzeingangsgrößen i_{k-1} (äquivalent zu den dem modellbasierten Ansatz zur Verfügung stehenden Größen setzen sich diese aus der Gierrate $\dot{\psi}_2$ und Längsgeschwindigkeit v_{x_2} des Sattelaufliegers zusammen), gefolgt von der betrachteten, um einen Zeitschritt verzögerten, zurückgeführten Zielgröße $t_{k-1,i}$. Anschließend werden abwechselnd um weitere Zeitschritte zurückliegende Netzeingangs- und zurückgeführte Zielgrößen zur Berechnung der Lipschitz-Indizes hinzugefügt. Aus den Verläufen der Lipschitz-Indizes in Bild 5.3 ist zu erkennen, dass die absoluten Werte über die drei betrachteten Manöver hinweg variieren, die qualitative Aussage jedoch weitestgehend konsistent bleibt. Die Methode liefert kein exaktes Kriterium zur Auswahl der Eingänge, dennoch kann bei der Zielgröße Reifenquerkraft $F_{y_{21}}$ bis zu einschließlich $n_{\text{ID}} = n_{\text{FD}} = 2$ eine deutliche Verringerung des Indexes festgestellt werden, während für den Knickwinkel bereits ab $n_{\text{ID}} = 2$, $n_{\text{FD}} = 1$ eine Stagnation der Indizes zu beobachten ist. Daraus lässt sich schließen, dass die erforderlichen Eingänge zur eindeutigen Berechnung der jeweiligen Zielgröße ab diesen Punkten eingeschlossen sind. Für den nachfolgend beschriebenen Ansatz der kombinierten Schätzung von beiden Zielgrößen innerhalb eines KNN werden daher die Zeitverzögerungen zu $n_{\rm ID} = n_{\rm FD} = 2$ gewählt.

Neben der Einstellung der Zeitverzögerungen ist eine Auswahl bezüglich der Anzahl an versteckten Schichten n_{HL} und der darin jeweils enthaltenen Neuronen n_{HN} zu treffen. Wie in Abschnitt 3.4 beschrieben hat sich in der Praxis ein empirisches Vorgehen als praktikabel erwiesen. Daher wird



Bild 5.3: Bestimmung der notwendigen Zeitverzögerungen des Eingangs n_{ID} und der Ausgangsrückführung n_{FD} in der Simulation anhand von Lipschitz-Indizes für 3 ausgewählte Manöver.

in dieser Arbeit durch systematische Kombination verschiedener Schicht- und Neuronenanzahl der Einfluss auf das Schätzergebnis untersucht. Das Vorgehen gestaltet sich wie folgt.



Bild 5.4: Einfluss der Anzahl der Trainingsdurchläufe auf den NRMSE bezogen auf einen Testdatensatz. Die Kastendiagramme fassen das Ergebnis jedes einzelnen Trainingsdurchlaufs für Netzauswahlansätze mit 10, 20 bzw. 50 Durchläufen am Beispiel eines Netzes mit 2 Schichten und 4 Neuronen pro Schicht zusammen.

Damit möglichst gleichermaßen Netztiefe (Anzahl der Neuronenschichten) und Netzbreite (Anzahl der Neuronen je Schicht) mit vertretbarem Rechenaufwand untersucht werden können, beschränkt sich die Untersuchung auf eine maximale Gesamtneuronenanzahl von 32 und die Anzahl der Schichten und Neuronen wird in Zweierpotenzen beginnend bei eins sukzessive gesteigert. Die Anzahl an Trainingsepochen wird auf 500 festgelegt, da eine Analyse des Verlaufs der zu optimierenden Kostenfunktion in Gleichung (3.5) vor dieser Epoche eine Konvergenz aufweist. Als Optimierungsalgorithmus wird der Levenberg-Marquardt Algorithmus mit Bayes'scher Regularisierung verwendet (vgl. Abschnitt 3.2). Zu Beginn eines jeden Trainingvorgangs werden die anzulernenden

Gewichte nach dem Nguyen-Widrow Algorithmus [NW90] initialisiert, was aufgrund des stochastischen Anteils innerhalb des Algorithmus bei jedem Durchlauf zu unterschiedlicher Initialisierung der Gewichte führt. Dies kann wiederum einen signifikanten Einfluss auf das Ergebnis haben, wie in Bild 5.4 zu erkennen ist. Wird für eine beispielhafte Netzarchitektur von 2 Schichten mit 4 Neuronen je Schicht das Training mehrmals wiederholt, weisen die Ergebnisse eine deutliche Streuung auf. Um eine Aussage bezüglich der Eignung einer Netzarchitektur treffen zu können, ist demnach ein Netzauswahlansatz mit wiederholten Trainings für jeden Netzkandidaten notwendig. In Bild 5.4 ist weiterhin zu sehen, inwiefern sich die Ergebnisse bei 10, 20 bzw. 50 Trainingsdurchläufen unterscheiden. Wird die Anzahl der Durchläufe erhöht, treten häufiger Ergebnisse mit größerer Abweichung auf. Das beste Ergebnis bei 10 Durchläufen kann durch eine erhöhte Anzahl von Trainings jedoch nicht signifikant verbessert werden. In dieser Arbeit wird daher die Anzahl der Trainingswiederholungen innerhalb des Netzauswahlansatzes auf 10 festgelegt und für den Vergleich zwischen den Netzkandidaten der jeweils beste Durchlauf bezogen auf einen Testdatensatz herangezogen. Insgesamt werden somit 180 Trainings durchgeführt, das Ergebnis ist Bild 5.5 zu entnehmen.



Bild 5.5: Untersuchung zur Auslegung der Netzarchitektur in der Simulation. Für jeden Netzkandidaten ist das beste erzielte Ergebnis aus 10 Trainingsdurchläufen auf einem Testdatensatz angegeben, das global beste Ergebnis ist mit einem roten Kreuz gekennzeichnet.

Als Struktur mit dem niedrigsten Fehler, beschrieben durch die Summe über die Wurzel der normalisierten Fehlerquadrate (engl. *Normalized Root Mean Square Error*, kurz: NRMSE) bezogen auf die beiden Zielgrößen Knickwinkel θ und Reifenquerkraft $F_{y_{21}}$, erweist sich das Netz mit einer Schicht und den darin enthaltenen 32 Neuronen, welches durch ein rotes Kreuz gekennzeichnet ist. Der NRMSE beträgt $2,02 \cdot 10^{-5}$. Es ist zu beobachten, dass sich die Netze mit einem Neuronen pro Schicht bei einer unterschiedlichen Anzahl von Schichten kaum in ihrer Genauigkeit unterscheiden. Selbiges weisen die unterschiedlich tiefen Netze mit zwei Neuronen je Schicht auf. Ab vier Neuronen pro Schicht ist dies nicht mehr der Fall und ab 8 Schichten ist die Abweichung zwischen wahrer Zielgröße und der vom Netz berechneten Zielgröße ohnehin auf einem sehr niedrigen Niveau von unter $2.7 \cdot 10^{-5}$. Die simulativen Ergebnisse werden im folgenden Abschnitt anhand ausgewählter Manöver dargestellt und dem modellbasierten Ansatz aus Abschnitt 5.1 gegenübergestellt.

5.3 Ergebnisse der modellbasierten und datenbasierten Zustandsschätzung

Für den Vergleich zwischen den Schätzergebnissen des modellbasierten und des datenbasierten Ansatzes werden die Eingangsgrößen von 6 unterschiedlichen, mit dem realen Versuchsfahrzeug durchgeführten Fahrten herangezogen, welche nicht im Trainingsdatensatz oder im Testdatensatz zur Auswahl der Netzarchitektur enthalten sind und mit Hilfe des Querdynamikmodells simuliert werden. Bei der Auswahl der Fahrten wird erneut auf ein breites Spektrum verschiedener Arbeitspunkte geachtet, damit die erzielten Ergebnisse einen möglichst ganzheitlichen Geltungsbereich aufweisen. In den Fahrten sind sowohl stationäre Manöver, wie beispielsweise eine stationäre Kreisfahrt, als auch dynamische Manöver bei verschiedenen Geschwindigkeiten und Lenkwinkelfrequenzen sowie -amplituden enthalten. Aufgrund dessen, dass in der Simulation künstlich stochastische Rauscheffekte für Mess- und Prozessrauschen hinzugefügt werden, kann das resultierende Ergebnis durch die zufällige Initialisierung der Rauschgeneratoren zu Beginn eines Simulationsdurchlaufs über mehrere Durchläufe unterschiedlich ausfallen. Daher wird jede Fahrt 20 mal simuliert, um den Einfluss der zufälligen Initialisierung herauszumitteln, was zu insgesamt 120 Simulationsdurchläufen führt. Das Gesamtresultat ist in Bild 5.6 als Kastendiagramme dargestellt.



Bild 5.6: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für optimal eingestellte Parameter und Filter. Die Parameter und Varianzen im Filter entsprechen exakt denen des Simulationsmodells zur simulativen Validierung bzw. zur simulativen Erzeugung von Trainingsdaten für das KNN.

In der ersten Zeile sind die RMSE zwischen simulierter Reifenquerkraft $F_{y_{21}}$ und den Schätzungen durch EKF, UKF und KNN für alle Simulationsdurchläufe zu sehen. Der Median des Fehlers für das EKF mit 1,64 kN und das UKF mit 1,63 kN liegen in einem sehr ähnlichen Bereich. Auch die Streuung tritt in vergleichbarem Maße auf. Das KNN weist einen etwas größeren Median des Fehlers von 1,89 kN auf, während die Differenz zwischen dem Durchlauf mit dem kleinsten und dem Durchlauf mit dem größten Fehler vergleichbar zu der der KF ist. In der zweiten Zeile sind analog die Fehler der Schätzung des Knickwinkels θ dargestellt. Auch für diese Größe liegen der Median des Fehlers für das EKF mit 3,54° dicht bei dem des UKF mit 3,55°, allerdings weist das UKF einen etwas geringeren Fehler für den schlechtesten Simulationsdurchlauf auf. Das KNN liefert für den Knickwinkel ein etwas besseres Ergebnis im Vergleich zu den KF mit einem Median des Fehlers von 3,26°. Auch der größte über einen Simulationsdurchlauf auftretende Fehler ist bei dem KNN erkennbar geringer als bei den KF. Der größten Fehler tritt für alle Schätzer beim gleichen Simulationsdurchlauf einer Kreisfahrt mit zunehmendem Lenkradwinkel auf und ist auf ein zufällig sehr ungünstiges Rauschen zurückzuführen. Im besten Simulationsdurchlauf des selben Manövers erzielen alle Schätzer eine RMSE von unter 5°.

Zur genaueren Analyse der Ergebnisse wird in Bild 5.7 beispielhaft der Zeitverlauf eines Simulationsdurchlaufs gezeigt. Es handelt sich dabei um zwei hintereinander folgende Lenkwinkelrampen, die erste nach rechts und die zweite nach links. Das EKF und das UKF schätzen neben den Zielgrößen Knickwinkel θ und Reifenquerkraft an der ersten Achse im Sattelauflieger $F_{y_{21}}$ gemäß Abschnitt 5.1 auch alle weiteren Zustände des Querdynamikmodells aus Kapitel 4 und darüber hinaus auch die unbekannte Eingangsgröße Lenkradwinkel $\delta_{\rm L}$. Das KNN liefert als Ausgangsgrößen lediglich die gewählten Zielgrößen, daher ist im Zeitverlauf des simulierten und der geschätzten Lenkradwinkel kein Verlauf des KNN abgebildet. Weiterführende Untersuchungen haben gezeigt, dass der Lenkradwinkel bei Bedarf analog zu den Zielgrößen als Netzausgang hinzugenommen oder durch ein separates KNN abgebildet werden kann [JZK+20]. Beim Vergleich zwischen den KF ist festzustellen, dass diese einen kaum zu unterscheidenden Verlauf aufweisen. Des Weiteren ist der Verlauf der KF stark verrauscht. Dies ist auf die gewählte Dynamik der Eingangsschätzung über die Einstellung der Prozessrauschkovarianz gemäß Gleichung (5.3) zurückzuführen. Würde diese kleiner gewählt, fiele das Rauschen zwar geringer aus, allerdings verhielte sich die Schätzung in diesem Fall sehr träge und die ohnehin recht hohe Latenz der Eingangsschätzung von bis zu 0,7 s stiege weiter an. Im Gegensatz dazu führt eine Erhöhung der Dynamik zwar zu einer geringeren Latenz, das Rauschen nimmt jedoch zu und führt bei zu großen Werten zur Instabilität der Beobachter. Bei den Zielgrößen Knickwinkel und Reifenquerkraft sind grundsätzlich zufriedenstellende Ergebnisse aller drei Beobachter zu sehen. Für den Knickwinkel ist bei genauerer Betrachtung eine bessere Schätzung durch das KNN gegenüber den KF zu erkennen, wobei EKF und UKF sich erneut nicht signifikant in ihren Schätzungen unterscheiden. Die simulierte Reifenquerkraft ist im Vergleich zu den anderen abgebildeten Größen deutlich stärker verrauscht. Auch hier unterscheiden sich EKF und UKF nur unwesentlich und weisen einen vergleichsweise glatten Verlauf auf, während die



Bild 5.7: Vergleich der Methoden zur Zustandsschätzung in der Simulation anhand zweier hintereinander folgender Lenkwinkelrampen. Dargestellt sind die Schätzergebnisse für die Zielgrößen Knickwinkel und Reifenquerkraft an der ersten Achse im Sattelauflieger, welche von allen Methoden geschätzt werden. Zusätzlich findet innerhalb der KF eine Schätzung der unbekannten Eingangsgröße Lenkradwinkel δ_L statt.

Schätzung des KNN etwas verrauschter erscheint. Das Ergebnis dieses Manövers deckt sich mit den grundlegenden Erkenntnissen aus Bild 5.6

Die in diesem Abschnitt gezeigten Ergebnisse sind unter der Annahme idealer Bedingungen und Einstellungen entstanden. So wurde beispielsweise eine exakte Kenntnis des Simulationsmodells innerhalb der Filter angenommen, inklusive gleicher Parametrierung. Auch die Kovarianzen des in der Simulation aufgebrachten Prozess- und Messrauschens wurde innerhalb der KF als exakt bekannt angenommen und eingestellt. Analog ist für die simulative Erstellung des Trainingsdatensatzes für das KNN das gleiche Modell bei unveränderter Parametrierung und unveränderten Rauschkovarianzen wie in der Testphase verwendet worden. Diese idealisierten Annahmen treffen

für den realen Einsatz der Methoden kaum bis gar nicht zu. Prozess- und Messrauschen können sich fortwährend aufgrund veränderlicher Umgebungsbedingungen oder aufgrund von Alterungserscheinungen der Komponenten verändern. Auch die physikalischen Parameter des Systems variieren potenziell über die Zeit aufgrund von Verschleiß von Komponenten oder durch externe Eingriffe, z.B. durch zu- oder abladen von Transportgütern. Daher wird der Einfluss solcher Variationen auf das Schätzergebnis nachfolgend in der Simulationsumgebung genauer untersucht.

5.4 Robustheit der Methoden bezüglich ausgewählter Systemänderungen

Die im vorherigen Abschnitt gezeigten simulativen Ergebnisse wurden unter den darin beschriebenen idealisierten Annahmen erzielt, welche auch in der Herleitung des KFs in seiner ursprünglichen linearen Form zugrunde liegen. So kann das lineare KF nur unter den folgenden Annahmen als mathematisch optimal angesehen werden:

- Exakte Modellierung des zu beobachtenden Systems (welches in der Simulation dem Simulationsmodell entspricht, siehe Bild 5.1) innerhalb der Filter,
- normalverteiltes sowie unkorreliertes Prozess- und Messrauschens und
- exakte Kenntnis der Kovarianzen des Prozess- und Messrauschens.

Die nichtlinearen Erweiterungen EKF und UKF bauen auf diesen Annahmen auf. Da diese in der Anwendung auf das reale System des Sattelzugs lediglich näherungsweise zutreffen, werden in den folgenden Unterabschnitten ausgewählte Abweichungen davon und deren Einfluss auf die Zustandsschätzung durch die zuvor vorgestellten Methoden untersucht. Es werden veränderliches Prozessrauschen und die Variation der Parameter Fahrzeugmasse des Sattelaufliegers, Postion des Schwerpunktes im Sattelauflieger, Reibwert zwischen Reifen und Fahrbahn sowie die Reifenparameter betrachtet. Für die rein modellbasierten Ansätze wäre die Sensitivitätsanalyse eine Alternative zu den nachfolgenden Untersuchungen, diese ist für die datenbasierten Ansätze bezüglich der physikalischen Systemparameter jedoch nicht umsetzbar.

5.4.1 Variation des Prozessrauschens im Simulationsmodell

Das Prozessrauschen beschreibt stochastische Einflüsse innerhalb des Systems. Bezogen auf den Sattelzug kann es beispielsweise durch zufällig eingebrachte Vibrationen durch das Straßenprofil auftreten. Die Auswirkung dieser Vibrationen auf die Zustandsgrößen kann darüber hinaus abhängig vom Alterungszustand der Fahrwerkskomponenten in der Intensität variieren. So werden bei verschlissenen Dämpfern die Krafteinträge in die Achsen weniger gedämpft auf den Aufbau übertragen. Das Prozessrauschen im Sattelzug variiert somit potenziell über den Streckenverlauf und den Produktlebenszyklus, was zu einer nicht optimalen Einstellung der Zustandsbeobachter und in der Konsequenz zu einer geringeren Schätzgüte führt. Diesem Problem kann für die

modellbasierten Ansätze beispielsweise durch eine rekursive Schätzung der Kovarianzen begegnet werden [RBD⁺15], [RDO16]. Das erfordert zusätzlichen Rechen- und Parametrierungsaufwand und wird daher innerhalb dieser Arbeit nicht weiter thematisiert, da die betrachteten Ansätze durch ihre Komplexität ohnehin schon an die Grenzen der Serientauglichkeit für den Sattelauflieger gelangen. Vielmehr wird ein Vergleich der Methoden bei unkorrekt eingestellten Filtern aufgrund von Änderungen im System des Sattelzugs, welche in der Simulation über eine Manipulation des Simulationsmodells abgebildet werden, angestrebt, um daraus die Robustheit der Methoden gegenüber solchen Effekten abzuleiten.

Der Ablauf der Untersuchungen gestaltet sich wie folgt: Wie zuvor beim Vergleich der Schätzmethoden unter idealisierten Annahmen wird ein perfektes Modell innerhalb der KF implementiert, d.h. die Zustandsgleichungen entsprechen genau denen des Simulationsmodells und die Parameter $p_{\text{Filt}} = p_{\text{Sim}}$ gleichen denen des Simulationsmodells. Auch die Kovarianz des Messrauschens wird optimal zu $R = R_{\text{Sim}}$ gewählt. Die datenbasierte Methode wird genau wie für den idealisierten Fall mit Trainingsdaten des Simulationsmodells angelernt, in denen keine Variation der Rauschterme oder der Parameter enthalten sind. Für die Untersuchungen bezüglich der Robustheit gegenüber veränderlichem Prozessrauschen wird im Simulationsmodell die Varianzmatrix Q_{Sim} stufenweise durch Multiplikation mit Zehnerpotenzen variiert. Das hat eine nicht mehr optimale Einstellung der Schätzer bezogen auf das zugrundeliegende System zur Folge. Da die in Simulation aufgebrachten Gauß'schen Rauschterme durch eine zufällige Initialisierung über mehrere Simulationsdurchläufe variieren, werden wie in Abschnitt 5.3 20 Simulationsdurchläufe je Fahrt simuliert. Die ausgewählten Fahrten für die Untersuchung entsprechen ebenfalls denen aus Abschnitt 5.3. Die Ergebnisse sind in Bild 5.8 dargestellt.

Die Schätzung der Reifenquerkraft wird für ein zehnfach höheres Prozessrauschen im Simulationsmodell für alle Ansätze deutlich schlechter. In 14 der 120 Simulationsdurchläufe wird das Modell oder einer der KF sogar instabil und führt zu Divergenz. Das größere Rauschen scheint sich auf alle Schätzer ähnlich auszuwirken, wobei die Differenz zwischen den KF und dem KNN weniger auffällt als bei optimaler Einstellung. Bei Verringerung des Prozessrauschens ist ein deutlich geringerer Einfluss auf das Schätzgüte für alle Methoden zu beobachten. Das geringere Rauschen führt zu stärker deterministisch geprägtem Verhalten des Simulationsmodells, was jedoch nur in einer leichten Verbesserung des Medians der Fehler resultiert, wobei dieser bei $Q_{\rm Sim} = Q \cdot 10^{-3}$ sogar wieder leicht ansteigt. Grundsätzlich liefern EKF und UKF sehr ähnliche Ergebnisse für alle Rauscheinstellungen und sind dem KNN etwas überlegen. Für den geschätzten Knickwinkel zeigt sich bei erhöhtem Rauschen ein ähnliches Bild wie für die Reifenquerkraft. Die Schätzung wird bei zunehmend stochastischem Systemverhalten für alle Schätzer in ähnlichem Maße schlechter. Bei kleinerem simulierten Prozessrauschen als für die Schätzer angenommen ist für den Vergleich zwischen EKF und UKF erneut ein sehr ähnliches Verhalten zu sehen, wobei der maximale Fehler für das UKF in den Fällen $Q \cdot 10^{-2}$ und $Q \cdot 10^{-3}$ etwas geringer ausfällt als der des EKF. Insgesamt wird der Median des Fehlers für die KF bis $Q \cdot 10^{-2}$ kleiner, bevor er dann wieder leicht ansteigt. Anders verhält es sich mit dem KNN. Dieses scheint, obwohl geringeres Prozessrauschen in den



Bild 5.8: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für unterschiedlich eingestelltes Prozessrauschen Q_{Sim} im Simulationsmodell. Die Einstellung innerhalb der Filter bzw. für die Erstellung des simulativen Trainingsdatensatzes für das KNN wird konstant bei $Q_{\text{Sim}} = Q$ belassen.

Trainingsdaten nicht vorliegt, vom abnehmenden Rauschen zu profitieren. Dies resultiert einerseits in einem durchschnittlich niedrigerem RMSE und in einer deutlich geringeren Streuung des Fehlers gegenüber den KF, andererseits wird die Schätzung mittels KNN mit abnehmendem Rauschen stetig etwas besser.

Zusammenfassend ist zu erkennen, dass sich die Veränderung des Prozessrauschens im Simulationsmodell der Sattelzugquerdynamik ohne Berücksichtigung dieser innerhalb der Schätzmethoden in Abhängigkeit von der betrachteten Schätzgröße unterschiedlich auswirken. Unter den gegebenen Bedingungen liefert das KNN für die Reifenquerkraft stets ein etwas schlechteres Resultat als die KF, wobei EKF und UKF sich in ihrer Qualität kaum unterscheiden. Für den Knickwinkel ist das KNN den KF stets leicht überlegen, wobei erneut EKF und UKF bezüglich der Schätzgüte kaum zu unterscheiden sind. Besonders für abnehmendes Prozessrauschen kann das KNN mit deutlich verringertem maximal auftretendem Fehler überzeugen. Grundsätzlich scheint ein sich verringerndes Prozessrauschen weniger problematisch bezogen auf die Schätzgüte zu sein, als ein sich vergrößerndes. Allerdings bleibt für die KF, insbesondere für den Knickwinkel, Verbesserungspotenzial durch eine optimale Einstellung ungenutzt. Es sei ausdrücklich erwähnt, dass die Übertragbarkeit der Ergebnisse auf den realen Sattelzug nur bedingt möglich ist, da insbesondere die Annahme eines perfekten Modells innerhalb der KF sowie die exakte Kenntnis der Rauschvarianzen unrealistisch erscheint. Tendenziell führt dies zu einer Überbewertung der KF in der Simulation. Nach der recht abstrakten Größe des Prozessrauschen werden im Folgenden ausgewählte Parameteränderungen untersucht.

5.4.2 Variation der Sattelaufliegermasse

Der Sattelauflieger dient in erster Linie dazu, Güter unterschiedlichster Form, Größe und Masse von einem Startpunkt aus zu einem dezidierten Ziel zu transportieren. Dabei kann allein die Masse zwischen ungefähr 7.500 kg für einen üblichen leeren Sattelauflieger bis hin zum zugelassenen Gesamtgewicht von 32.000 kg variieren und stell somit eine deutlich größere Spanne als bei einem PKW dar. Diese große Menge an möglichen Beladungszuständen hat erwartungsgemäß einen Einfluss auf die Dynamik des Fahrzeugs und darüber hinaus auch auf den Lasteintrag, dem die Fahrzeugkomponenten ausgesetzt werden. Um in der Simulation die Wirkung einer veränderlichen Sattelaufliegermasse zu untersuchen, wird analog zum Vorgehen bei den Untersuchungen zur Prozessrauschkovarianz die Masse des Sattelaufliegers im Simulationsmodell variiert, während die in den KF hinterlegten Modellen eine feste Parametrierung bei einer mittleren Beladung von 24.000 kg erhalten. Das Prozess- und Messrauschen wird bei der optimalen Einstellung aus Abschnitt 5.1 belassen. Um vergleichbare Bedingungen für den datenbasierten Ansatz mittels KNN zu simulieren, wird ein simulativer Trainingsdatensatz bei einer Parametrierung des Simulationsmodells für eine mittlere Beladung erstellt und damit das KNN angelernt. Somit kennt das KNN aus den Trainingsdaten keine variable Sattelaufliegermasse. In der Testphase werden die variabel parametrierten Simulationsmodelle erneut anhand der gleichen Fahrten und aus zuvor genannten Gründen mehrfach simuliert (vgl. Abschnitt 5.4.1). Die Ergebnisse sind Bild 5.9 zu entnehmen.

Bei der Schätzung der Reifenquerkraft ist eine ausgeprägte Sensitivität der Ergebnisse bezüglich einer Massenänderung zu erkennen. Sowohl bei Massenzunahme als auch bei einer Abnahme verschlechtert sich die Schätzgüte deutlich. Die falsch angenommene Masse im Modell der Filter bewirkt eine zu hoch oder zu niedrig angenommene Aufstandskraft (vgl. Gleichungen 4.14-4.16). Das hat wiederum Auswirkungen auf die modellierten Reifenquerkräfte (Gleichung 4.3). Der datenbasierte Ansatz kennt aus dem Trainingsdatensatz nur eine Masse und berechnet daher auch eine dazu gehörige Reifenquerkraft. Des Weiteren ist zu sehen, dass die aus den vorherigen Untersuchungen bekannte Überlegenheit der Filter gegenüber dem KNN bei einer abweichenden Parametrierung schwindet. Die Ergebnisse der Knickwinkelschätzung ergeben ein anderes Bild. Eine veränderte Sattelaufliegermasse scheint nahezu keinen Einfluss auf die Abbildungsgüte zu haben. Für alle Schätzer und jegliche Variation der Masse liegt der Median des Fehlers bei ungefähr 3°, wobei das KNN stets einen etwas niedrigeren RMSE sowohl im Median als auch in den



Bild 5.9: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für unterschiedliche Parametrierungen der Masse $m_{2_{\text{Sim}}}$ im Simulationsmodell. Die Parametrierung innerhalb der Filter bzw. für die Erstellung des simulativen Trainingsdatensatzes für das KNN wird konstant bei 24.000 kg belassen.

Maximalwerten aufweist. Der jeweils minimale Fehler über die betrachteten simulierten Fahrten wird hingegen durch die KF erzielt. Das Resultat erscheint plausibel, da der Knickwinkel bei einer beispielhaften Durchfahrt eines Kreisels unabhängig von der Beladung sehr ähnlich ist. An dieser Stelle sei wiederholt erwähnt, dass die Gültigkeit des Simulationsmodells lediglich für stabile Fahrsituationen gilt.

Einen tieferen Einblick in die Konsequenz einer zu der in den Schätzern parametrierten abweichenden Sattelaufliegermasse erlaubt Bild 5.10. Es wird ein beispielhaftes Fahrmanöver mit einer im Simulationsmodell eingestellten Sattelaufliegermasse von $m_{2_{\text{Sim}}} = 8.000 \text{ kg}$ gezeigt, bei dem die Schätzer von einer Masse von $m_{2_{\text{Filt}}} = 24.000 \text{ kg}$ ausgehen. Im Zeitverlauf ist eine gute Übereinstimmung zwischen simuliertem und geschätztem Knickwinkel zu sehen, der RMSE liegt für die KF bei ungefähr 2,70° und für das KNN bei 2,36°. Für die Reifenkräfte ist eine deutliche Überschätzung der Reifenkräfte erkennbar, was auf die zu hoch angenommene Masse zurückzuführen ist. Dabei verhalten sich alle Schätzer wiederum sehr ähnlich. Zusätzlich ist noch die



Bild 5.10: Vergleich der vorgestellten Methoden anhand eines Manövers aus dem Testdatensatz. Für die Implementierung der Schätzer wurde eine Sattelaufliegermasse von $m_{2_{\text{Filt}}} = 24.000 \text{ kg}$ angenommen, in der Simulation des Manövers jedoch eine Masse von $m_{2_{\text{Sim}}} = 8.000 \text{ kg}$ eingestellt. Neben den Zielgrößen Knickwinkel und Reifenquerkraft der ersten Sattelaufliegerachse wird zusätzlich die innerhalb der KF stattfindende Eingangsschätzung des Lenkradwinkels dargestellt.

innerhalb der KF notwendige Schätzung des Lenkradwinkels abgebildet, welche trotz abweichend angenommener Masse ohne größere Abweichungen funktioniert. Auch hier ist kein signifikanter Unterschied zwischen EKF und UKF erkennbar.

Zusammenfassend wird deutlich, dass eine Variation der Sattelaufliegermasse auf die Knickwinkelschätzung nur einen geringen Einfluss hat, während die Reifenquerkraftschätzung deutliche Sensitivität bezüglich dieses Parameters aufweist. Somit ist insbesondere für eine korrekte Reifenkraftschätzung eine Bestimmung der tatsächlich vorliegenden Masse erforderlich. Im Rahmen des modellbasierten Ansatzes wäre eine echtzeitfähige Massenschätzung denkbar. Dafür wären jedoch weitere Informationen erforderlich, die auf die Masse des Fahrzeugs schließen lassen, wie beispielsweise zur Erfassung der Drücke in den Federbälgen oder der Aufstandskraft an der Sattelplatte. Alternativ können auf dem CAN Bus des Sattelaufliegers vorliegende Informationen des Luftfedersystems mit der Massenschätzung fusioniert oder alternativ direkt zur Nachparametrierung der Masse genutzt werden. Auch dem datenbasierten Ansatz kann diese Information als Eingangsgröße zugeführt werden. Diese Lösungsansätze wurden im Rahmen der vorliegenden Arbeit aufgrund fehlender Messreihen mit unterschiedlicher Beladung nicht weiter betrachtet.

5.4.3 Variation des Massenschwerpunkts im Sattelauflieger

Neben der zuvor variierten Fahrzeugmasse des Sattelaufliegers kann durch verschiedene Beladungszustände auch die Schwerpunktposition sehr unterschiedlich sein. Bei unzureichender Ladungssicherung kann sogar während einer Fahrt eine Verschiebung der Ladung auftreten. Um auch diese möglichen Vorkommnisse zu untersuchen, erfolgt analog zur vorhergegangenen Variation der Masse im Folgenden eine Variation der Schwerpunktposition in Fahrzeuglängsrichtung innerhalb des Simulationsmodells und eine nachfolgende Analyse der Auswirkungen. Die Ausgangssituation bildet erneut der teilbeladene Sattelauflieger mit einer Masse von $m_{2_{\text{Sim}}} = 24.000 \text{ kg}$ und einer Position des Schwerpunkts $x_{\text{SP}_{\text{Sim}}}$ bezogen auf die Rückwand des Sattelaufliegers von 7,8 m. Darauf folgt anschließend eine sukzessive Verschiebung der Position des Schwerpunktes nach vorne und nach hinten. Das Resultat ist in Bild 5.11 zu sehen.

Insgesamt ergibt sich ein ähnliches Bild zur Variation der Sattelaufliegermasse. Für den Knickwinkel zeigt sich erneut eine grundsätzlich robuste Schätzgüte gegenüber der Schwerpunktverschiebung. Im Gegensatz zur Massenänderung zeigt sich allerdings eine größere Streuung mit höheren Maximalwerten beim KNN gegenüber den KF. Die Güte der Reifenquerkraftschätzung nimmt mit zunehmender Verschiebung nach vorne und nach hinten gleichermaßen ab, wobei für eine Verschiebung von $-2 \,\mathrm{m}$ während 11 der 60 Simulationsdurchläufe alle Schätzer instabil wurden. Grund dafür könnte eine auftretende Bifurkation sein, wie sie unter Anderem für Sattelzüge in [Lui10] beschrieben werden. Im Allgemeinen ist unter Bifurkation die parameter- und arbeitspunktabhängige Änderung des qualitativen Verhaltens eines nichtlineare Systems zu verstehen. Eine starke Variation des Schwerpunkts im Sattelauflieger ruft ein gänzlich unterschiedliches Systemverhalten hervor, bis hin zur Instabilität in entsprechenden Arbeitspunkten. Somit hat auch die Schwerpunktposition einen erheblichen Einfluss auf die Reifenquerkraftschätzung, welchen es für eine korrekte Ermittlung in der Onlineanwendung zu berücksichtigen gilt. Auch dies könnte über eine hinzugenommene Parameterschätzung für die modellbasierten Ansätze und über einen entsprechend vielfältigen Trainingsdatensatz berücksichtigt werden, allerdings ist die Beobachtbarkeit bzw. Sensitivität bezüglich dieses Parameters in den auftretenden Fahrsituationen zu prüfen.



Bild 5.11: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für unterschiedliche Parametrierungen der Schwerpunktposition in Fahrzeuglängsrichtung $x_{SP_{Sim}}$ im Simulationsmodell. Die Parametrierung innerhalb der Filter bzw. für die Erstellung des simulativen Trainingsdatensatzes für das KNN wird konstant bei $x_{SP_{Filt}} = x_{SP-teilbeladen} = 7,8 m$ belassen.

5.4.4 Variation des Reibwerts

Der vorliegende Reibwert zwischen den Reifen und der Fahrbahnoberfläche ist ein entscheidender Parameter für die auftretenden Kontaktkräfte zwischen einem Fahrzeug und seiner Umgebung. Er verändert sich fortlaufend in Abhängigkeit von Straßenbeschaffenheit, dem Wetter, dem Reifenzustand und weiteren Faktoren. Um die Auswirkung einer Reibwertänderung auf die Schätzgüte zu untersuchen, wird in der Simulation, angelehnt an das Vorgehen der vorangegangenen Untersuchungen, der Reibwert μ_{Sim} im Simulationsmodell variiert. Im Querdynamikmodell wird der Reibwert für die einzelnen Achsen des Sattelzugs nicht differenziert und als gleich angenommen. Der Bereich der Variation schließt Reibwerte unter 0,5 aus, da aufgrund fehlender experimenteller Validierungsdaten in diesem Bereich keine Aussage über die Qualität des Modells getroffen werden kann. Im Maximum wird der Reibwert in der Untersuchung auf 1,1 begrenzt, was nach [KN05] ungefähr dem maximalen in der Realität aufkommenden Reibwert entspricht. Ausgehend von einem Reibwert im Simulationsmodell bei $\mu_{\text{Sim}} = 0.9$ wird dieser in beide Richtungen variiert, während der Reibwert innerhalb der KF und für den simulativen Trainingsdatensatz des KNN erneut unverändert bei $\mu_{\text{Filt}} = 0.9$ bleibt. Das Resultat der Untersuchung ist in Bild 5.12 dargestellt.



Bild 5.12: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für unterschiedliche Parametrierungen des Reibwerts μ_{Sim} im Simulationsmodell. Die Parametrierung innerhalb der Filter bzw. für die Erstellung des simulativen Trainingsdatensatzes für das KNN wird konstant bei $\mu_{\text{Filt}} = 0.9$ belassen.

Für die Reifenquerkraft ist eine deutliche Abnahme der Schätzgüte bei von den Annahmen der Schätzer abweichendem Reibwert im Simulationsmodell zu erkennen. Bei einer Abweichung zu niedrigerem Reibwert hin nehmen Median als auch Streuung für alle Schätzer etwas stärker zu als bei erhöhtem Reibwert. Besonders kritisch zeigt sich die Güte der Schätzung bei einem Reibwert von 0,5, bei der z.T. erhebliche Fehler auftreten. Darüber hinaus ist eine zunehmende Annäherung der KF und des KNN bei steigender Abweichung zu erkennen, wobei das KNN im Median für $\mu_{\text{Sim}} \neq \mu_{\text{Filt}}$ stets etwas besser abschneidet und EKF und UKF sich nahezu identisch zeigen. Die Schätzung des Knickwinkels scheint erneut fast unbeeinflusst von einer Reibwertänderung zu sein. Die KF dominieren durchweg leicht gegenüber dem KNN, insbesondere was das Minimum angeht. Grundsätzlich sind die Ergebnisse aller Schätzer sehr vergleichbar. Es wird deutlich, dass für eine korrekte Schätzung der Reifenquerkräfte eine genaue Kenntnis über den Reibwert erforderlich ist. Aufgrund seiner Sicherheitsrelevanz ist die echtzeitfähige Reibwertschätzung im Fahrzeug Gegenstand zahlreicher Forschungsarbeiten, u.A. [Bec18], [Wie20]. Im Rahmen der modellbasierten Zustandsschätzung für die vorliegende Problemstellung könnte ebenfalls eine Erweiterung um eine Reibwertschätzung die Abbildungsgüte über alle Reibwertbereiche hinweg verbessern. Allerdings wäre genau wie in den genannten Vorarbeiten eine Untersuchung der Sensitivität dieses Parameters und damit einhergehend die Beobachtbarkeit zu prüfen. Für den datenbasierten Ansatz wäre eine Erweiterung des Trainingsdatensatzes um Fahrmanöver mit einem breiten Spektrum an unterschiedlichen Reibwerten zwischen Reifen und Fahrbahn denkbar, um die Adaption an einen veränderlichen Reibwert anzulernen. Dabei könnten weitere Messgrößen erforderlich werden, damit der Reibwert beobachtbar wird. In einer eigenen Veröffentlichung konnte der Erfolg dieses Vorgehens anhand einer Schwimmwinkelschätzung im PKW gezeigt werden [ZBW21]. Aufgrund fehlender Möglichkeiten zur Aufnahme entsprechender experimenteller Messdaten konnte dies nicht für den Sattelzug in dieser Arbeit durchgeführt werden.

5.4.5 Variation der Reifencharakteristik im Sattelauflieger

Einen weiteren grundsätzlich variablen Faktor in der Fahrzeugdynamik stellt neben dem Reibwert zwischen Reifen und Fahrbahn das charakteristische Verhalten des Reifens unter Krafteinwirkung dar. Auf dem Markt sind diverse Reifenhersteller vertreten, die jeder für sich eine Vielzahl verschiedener Reifenmodelle anbieten. Die Reifen können sich je nach eingesetztem Material, Herstellungsprozess, Form, Größe und Profil in ihrer Charakteristik unterscheiden. Darüber hinaus haben der eingestellte Reifenluftdruck sowie der aktuelle Reifenzustand, der aufgrund von Verschleiß und Schädigung variiert, ebenfalls eine Veränderung der Reifencharakteristik zur Folge. Für eine experimentelle Untersuchung all dieser Effekte und deren Auswirkung auf die vorgestellten Methoden wären Daten umfangreicher Messfahrten mit variierender Bereifung und damit einhergehenden detaillierten Untersuchungen notwendig, welche im Rahmen der Arbeit nicht zur Verfügung stehen. Um dennoch zumindest eine Abschätzung über den Einflusses einer abweichenden Bereifung im Sattelauflieger im Vergleich zu der innerhalb der Schätzer angenommenen vornehmen zu können, kommen erneut simulative Untersuchungen zum Einsatz.

Für die Parameter Sattelaufliegermasse und dessen Schwerpunkt lässt sich die im realen Einsatz vorkommende Variation über eine Plausibilitätsprüfung gut abschätzen (z.B. Masse zwischen Leergewicht und maximal zugelassenem Gesamtgewicht, Schwerpunkt nicht außerhalb des Sattelaufliegers). Dagegen ist für die Parameter des Reifenmodells innerhalb des vorgestellten Einspurmodells aus Kapitel 4 im Vorfeld der Untersuchungen nicht bekannt, inwiefern sich diese für unterschiedliche Bereifung verändern. Aus diesem Grund werden anstelle einer linearen Variation einzelner Parameter die vier Reifenparameter des Sattelaufliegers $p_{RS} = (C_2, c_{12}, c_{22}, l_{R_2})$ gleichzeitig und quasi-zufällig unter Zuhilfenahme einer Sobol-Sequenz in einem definierten Bereich variiert [JK03]. Durch die Sobol-Sequenz lässt sich, im Vergleich zu einer unabhängigen Gleichverteilung der einzelnen Parameter, der mehrdimensionale Parameterraum mit einer geringeren Anzahl beispielhafter Parametersätze gleichmäßig abdecken. Dies verringert die Anzahl der notwendigen Simulationen, um ein aussagekräftiges Ergebnis zu erhalten. Zur Untersuchung des Einflusses der Reifencharakteristik im Sattelauflieger auf die Schätzung wird für die Parametrierung des Simulationsmodells systematisch von den entsprechenden ursprünglich identifizierten Parametern p_{opt} abgewichen. Die Abweichung für die vier untersuchten Parameter wird sukzessive in $\pm 10\%$ Schritten bis zu $\pm 30\%$ (bezogen auf p_{opt}) erhöht und für jede Stufe ein quasi-zufälliger Satz von 20 Parametrierungen gemäß der Sobol-Sequenz erzeugt. Mit jedem dieser Parametersätze wird die Simulation aufgrund der nach wie vor zufällig hinzugefügten Rauschterme fünf mal je ausgewählter Fahrt durchgeführt. Für die KF sowie für die Erstellung des simulativen Trainingsdatensatzes für das KNN werden die Reifenparameter des Sattelaufliegers bei den Werten aus p_{opt} belassen. Dies führt insgesamt zu 2.400 Simulationsdurchläufen, deren Ergebnisse in Bild 5.13 zusammenfassend dargestellt sind.



Bild 5.13: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für unterschiedliche Parametrierungen der Reifenmodelle im Simulationsmodell. Die Parametrierung innerhalb der Filter bzw. für die Erstellung des simulativen Trainingsdatensatzes für das KNN wird konstant bei den Werten aus p_{opt} belassen.

Zunächst wird die Schätzung der Reifenquerkraft genauer betrachtet. Bei einer Parameterunsicherheit von $\pm 10\%$, $\pm 20\%$ bzw. $\pm 30\%$ nimmt die Schätzgüte im Median um 4,6\%, 23,8\% bzw. 50,9% ab. Im Maximum werden diese Werte sogar deutlich übertroffen, während im Minimum aufgrund zufällig sehr ähnlicher Parametrierung in den Schätzern und dem Simulationsmodell die Schätzgüte annähernd gleich bleibt. Erneut zeigen sich die KF dem KNN leicht überlegen. Die Knickwinkelschätzung zeigt sich auch bei einer Variation der Reifenparameter des Sattelaufliegers kaum beeinflusst. Über alle Abstufungen hinweg bleiben die Fehlermaße vergleichbar, das UKF stellt sich stets als etwas genauer im Vergleich zum EKF heraus. Das KNN kann besonders durch eine noch geringere Streuung als das UKF überzeugen.

Eine letztendliche Übertragung und Beurteilung der Ergebnisse für die Reifenquerkraftschätzung im realen Versuchsträger fällt schwer. Einerseits sind keine Erfahrungen über die tatsächlich vorkommende Streuung der Parameter bekannt, andererseits liegen keine quantifizierten Genauigkeitsanforderungen an die Reifenquerkrafschätzung im Bezug auf die Abschätzung von Verschleißund Schädigungserscheinungen vor. Dafür sind weiterführende Untersuchungen notwendig, die in dieser Arbeit nicht weiter beschrieben werden.

5.5 Fazit

In diesem Kapitel wurde die Anwendung der zuvor theoretisch erläuterten Ansätze der modellbasierten und datenbasierten Zustandsschätzung auf den Sattelauflieger zur Bearbeitung der in der Einleitung vorgestellten Problemstellung beschrieben. Dabei ist an Stelle des realen Versuchsträgers zunächst das in Kapitel 4 beschriebene Simulationsmodell getreten. Die Vorteile der Untersuchungen in der Simulation liegen darin, dass jegliche Bedingungen exakt vorgegeben werden können und somit bekannt sind. Das erlaubt eine detaillierte Untersuchung der verwendeten Methoden ohne etwaige Störeinflüsse und ist darüber hinaus zeit- und kosteneffizienter im Vergleich zu einer experimentellen Betrachtung. Nach einer genauen Beschreibung der Implementierung der Methoden wurden diese zunächst unter optimalen Einstellungen miteinander verglichen. Da diese optimalen Gegebenheiten eher als realitätsfern anzusehen sind, wurden anschließend systematische Untersuchungen bezüglich ausgewählter Abweichungen vom Optimalfall mit Realitätsbezug durchgeführt.

Zusammenfassend lassen sich folgende Schlüsse aus den simulativen Ergebnissen ziehen. Der Vergleich von EKF zu UKF zeigt über alle Ergebnisse hinweg für die Schätzung der Zielgrößen des Knickwinkels und der Reifenquerkraft an der ersten Achse des Sattelaufliegers innerhalb der Sattelzugquerdynamik und unter den getroffenen Annahmen lediglich einen marginalen Unterschied. Daher sollten für eine Auswahl zwischen den beiden KF weitere Faktoren wie beispielsweise Implementierungs- oder Rechenaufwand herangezogen werden. Das KNN zeigt sich in der Simulation gegenüber den KF in den meisten Fällen der Reifenquerkraftschätzung unterlegen. Für die Knickwinkelschätzung ist die Güte der KNN vergleichbar mit den KF. Insbesondere bei abweichendem Prozessrauschen sowie variierender Sattelaufliegermasse und Reifencharakteristik der Sattelaufliegerachsen können Tendenzen einer geringeren Streuung mit niedrigeren maximalen Abweichungen erkannt werden. Unabhängig von der betrachteten Methode wird deutlich, dass sich die Knickwinkelschätzung deutlich robuster gegenüber jeglichen Veränderungen zeigt als die Schätzung der Reifenquerkraft. Dies lässt vermuten, dass der Zusammenhang der Messund Eingangsgrößen mit dem Knickwinkel eher kinematischer Natur sind. Die Sensitivität der Reifenquerkraftschätzung gegenüber der Parameteränderungen lässt die Forderung nach einer Erweiterung um eine echtzeitfähige Adaption an diese Parameteränderungen verstärkt in den Fokus rücken. Allerdings ist fraglich, ob alle der einflussreichen Parameter gleichzeitig geschätzt bzw. adaptiert werden können.

Nachteil der simulativen Untersuchungen ist die Ungewissheit bezüglich der Übertragbarkeit der Ergebnisse in die Realität, denn diese gelten zunächst ausschließlich unter den getroffenen Annahmen. Es besteht eine hohe Wahrscheinlichkeit, dass zumindest nicht alle Annahmen als realistisch anzusehen sind. Aus diesem Grund widmet sich das nachfolgende Kapitel der experimentellen Untersuchung der vorgestellten modellbasierten und datenbasierten Methoden.

6 Echtzeitfähige Zustandsschätzung im Sattelzug

Die Eignung der in dieser Arbeit vorgestellten Methoden zur Erreichung der eingangs erläuterten Ziele wurden im Kapitel 5 zunächst unter idealisierten Annahmen in der Simulation gezeigt. Darüber hinaus konnte durch eine isolierte Betrachtung ausgewählter Abweichungen, angelehnt an mögliche im Serienfahrzeug auftretenden Szenarien, eine Abschätzung bezüglich deren Auswirkungen auf die Zustandsschätzung gegeben werden. Dieses Kapitel widmet sich nun der experimentellen Untersuchung anhand des realen Versuchsfahrzeugs (Abschnitt 4.2.1). Dabei ist das Vorgehen grundsätzlich vergleichbar mit der simulativen Betrachtung, der wesentliche Unterschied liegt darin, dass an Stelle des Simulationsmodells in Bild 5.1 das Versuchsfahrzeug tritt und die Algorithmen online auf einer prototypischen Hardware im Fahrzeug ausgeführt werden. Dieses Kapitel gliedert sich in die folgenden Abschnitte. Zunächst wird in Abschnitt 6.1 die Einstellung der KF erläutert und in Abschnitt 6.2 analog die Entwicklung des datenbasierten Ansatzes für den Einsatz am realen Fahrzeug beschrieben. Die Daten zur Modellierung, zur Identifikation der Modellparameter, zum Einstellen der KF und zum Antrainieren des KNN werden auf einer Teststrecke aufgenommen. Die experimentellen Ergebnisse der Zustandsschätzung für ausgewählte Fahrmanöver werden in Abschnitt 6.3 beleuchtet. Dabei wird bewusst zwischen höherdynamischen Manövern auf der Teststrecke, welche in besonderem Maße die Nichtlinearitäten des Systems anregen und in Extremfällen vereinzelt auch im Straßenverkehr aufkommen können, und eher praxisorientierten Manövern im öffentlichen Straßenverkehr differenziert. Im Hinblick auf einen möglichen Serieneinsatz ist weiterhin die Abschätzung der erforderlichen Rechenleistung von Interesse, einen Einblick darin gewährt Abschnitt 6.3.3. Abschließend folgt ein Fazit der erzielten Ergebnisse. Die echtzeitfähige modellbasierte Zustandsschätzung am Sattelzug wurde in [ZKW+19] und die datenbasierte Knick- und Lenkwinkelschätzung wurde in [JZK⁺20] veröffentlicht.

6.1 Modellbasierte Zustandsschätzung

In der Simulation gestaltet sich die optimale Einstellung der KF trivial. Die Varianzen der synthetisch hinzugefügten Rauschterme sind genau bekannt und können entsprechend innerhalb der KF eingestellt werden. Einzig der Eintrag für die Eingangsschätzung wird entsprechend der gewünschten Dynamik eingestellt (vgl. Abschnitt 5.1). Für das reale Versuchsfahrzeug sind die Varianzen jedoch nicht bekannt. Für die Einstellung der Messrauschkovarianz besteht ein gängiges Vorgehen darin, die Varianz des Sensorausgabewertes im Stillstand zu bestimmen [Wie20]. Da die Messung der Gierrate des Sattelaufliegers $\dot{\psi}_2$ gemäß Gleichung (4.24) indirekt aus der Raddrehzahldifferenz bestimmt wird und die Raddrehzahlen wiederum durch passive Sensoren ermittelt werden, ist eine Messung im Stillstand nicht möglich. Daher wurde alternativ die Varianz des Messrauschens für Geradeausfahrten bei unterschiedlichen Geschwindigkeiten berechnet und anschließend gemittelt. Das führt letztlich gerundet zu dem Wert

$$\boldsymbol{R} = \left(10^{-4}\right) \quad . \tag{6.1}$$

Das Prozessrauschen hingegen lässt sich über Messungen solcher Art nicht bestimmen, zumal das identifizierte Modell aufgrund der Anforderung auf Echtzeitfähigkeit eine vereinfachte Abstraktion des realen Systems darstellt. Die bei dieser Abstraktion auftretende Ungenauigkeit wird innerhalb der KF im Prozessrauschen, unter den für die KF geltenden Annahmen, mitberücksichtigt. In dieser Arbeit werden die Prozessrauschvarianzen daher empirisch anhand von Offlinedurchläufen der KF für ausgewählte Fahrmanöver ermittelt und zu

$$\boldsymbol{Q} = \operatorname{diag}\left(10^{-10}, 10^{-10}, 5 \cdot 10^{-8}, 10^{-9}, 10^{-10}, 10^{3}, 10^{3}, 10^{3}, 10^{3}, 10^{3}, 10^{-5}\right)$$
(6.2)

festgelegt. Die Manöver wurden so gewählt, dass sie einen möglichst großen Teil der Arbeitsraums abdecken. Bei der Bewertung wurde ein Kompromiss aus Robustheit und Einschwingdauer getroffen, sodass ein möglichst geringer durchschnittlicher Schätzfehler auftritt. Ein alternativer Ansatz wäre die Bestimmung der Varianzen über einen Optimierungsalgorithmus, was aus Erfahrung eine unwesentliche Verbesserung bewirkt.

Die Parametrierung der Modelle für die Prozessgleichung innerhalb der KF erfolgt entsprechend der Ergebnisse aus der Parameteridentifikation in Abschnitt 4.2.2. Für das UKF werden darüber hinaus die Parameter

$$\alpha_{\rm UKF} = 1, \quad \beta_{\rm UKF} = 2 \quad \text{und} \quad \kappa_{\rm UKF} = 0 \tag{6.3}$$

analog zu den Ausführungen im simulativen Abschnitt 5.1 gewählt. Die Schätzung wird zu Beginn mit Nullen für alle Einträge des Zustandsvektors initialisiert, da zu diesem Zeitpunkt keine genaueren Kenntnisse vorliegen. Die experimentellen Ergebnisse der modellbasierten Zustandsund Eingangsschätzung werden im Abschnitt 6.3 denen der datenbasierten Zustandsschätzung gegenüber gestellt.

6.2 Datenbasierte Zustandsschätzung

Für die datenbasierte Zustandsschätzung am realen Versuchsträger bleibt das Vorgehen weitestgehend identisch zu dem der simulativen Untersuchungen, lediglich die simulativen Trainingsdaten werden durch real gemessene Daten ersetzt, wobei die verwendeten Manöver für die Datenbasis identisch sind (vgl. Abschnitt 5.2.1). Auch die Netzauslegung erfolgt analog zum simulativen Teil. Zunächst werden die erforderlichen Zeitverzögerungen des Eingangs $n_{\rm ID}$ und der Ausgangsrückführung $n_{\rm FD}$ mit Hilfe der Lipschitz-Indizes bestimmt [HA93] (vgl. Abschnitt 5.2.2). Die Lipschitz-Indizes, berechnet anhand von drei beispielhaft gewählter Manöver, für Knickwinkel θ und Reifenquerkraft $F_{y_{21}}$ sind in Bild 6.1 dargestellt. Wird das Ergebnis mit dem der simulativ erstellten Daten in Bild 5.3 verglichen, sind zwar quantitativ Unterschiede erkennbar, jedoch ein sehr ähnlicher qualitativer Verlauf festzustellen. Daher führt in der Folge auch für die experimentellen Untersuchungen die Wahl zu $n_{\rm ID} = n_{\rm FD} = 2$.



(a) Lipschitz-Indizes für den Knickwinkel θ als Zielgröße t

(b) Lipschitz-Indizes für die Reifenquerkraft $F_{y_{21}}$ als Zielgröße t

Bild 6.1: Bestimmung der notwendigen Zeitverzögerungen des Eingangs n_{ID} und der Ausgangsrückführung n_{FD} für das reale Versuchsfahrzeug anhand von Lipschitz-Indizes dreier beispielhaft gewählter Manöver.

Nachdem die Zeitverzögerungen festgelegt sind, folgt die Auslegung der Netzarchitektur. Auch dafür wird analog zum simulativen Abschnitt 5.2.2 verfahren und eine Rastersuche durchgeführt, bei der sukzessive verschiedene Netzbreiten und Netztiefen jeweils 10-fach antrainiert und die Ergebnisse anhand eines Testdatensatzes evaluiert werden. Die Ergebnisse des jeweils besten Trainings für die betrachtete Netzstruktur sind in Bild 6.2 dargestellt. Auch die Güte der verschiedenen Netzstrukturen führt qualitativ zu einer ähnlichen Beobachtung wie für die in der Simulation erzeugten Daten. Für lediglich ein Neuron pro Schicht werden über alle betrachteten Netztiefen ähnlich unbefriedigende Ergebnisse erzielt. Eine Erweiterung auf jeweils zwei Neuronen pro Schicht reduziert den NRMSE bereits deutlich um ungefähr 75 %. Ab vier Neuronen pro Schicht liegt der NRMSE unter 0,03 für alle betrachteten Architekturen, wobei der kleinste Fehler für die Struktur mit acht Schichten und jeweils vier Neuronen verzeichnet wird (gekennzeichnet mit einem roten Kreuz). Daher wird dieses Netz für die weiteren Betrachtungen ausgewählt.

Nachdem die Anpassungen der modellbasierten als auch der datenbasierten Zustandsschätzung für die Anwendung im realen Versuchsfahrzeug dargestellt wurden, widmet sich der nachfolgende Abschnitt der experimentellen Untersuchung und dem Vergleich der Methoden.



Bild 6.2: Untersuchung zur Auslegung der Netzarchitektur für das reale Versuchsfahrzeug. Für jeden Netzkandidaten ist das beste erzielte Ergebnis aus 10 Trainingsdurchläufen auf einen Testdatensatz angegeben, das global beste Ergebnis ist mit einem roten Kreuz gekennzeichnet.

6.3 Experimentelle Ergebnisse und Vergleich der Methoden

Wie bereits eingangs dieses Kapitels erwähnt, erfolgt die in diesem Abschnitt thematisierte experimentelle Validierung der betrachteten Methoden zweigeteilt. Zunächst werden höherdynamische Manöver auf einer Teststrecke betrachtet, welche die nichtlinearen Bereiche der Fahrdynamik und damit einhergehend auch des fahrdynamischen Modells anregen. Gegenüber potenziellen linearen Modellen (beispielsweise Kleinwinkelnäherung, lineare Reifenmodelle etc.) zeigt sich erst in diesen Bereichen ein signifikanter Mehrwert der nichtlinearen Modelle in der Zustandsschätzung. Darüber hinaus sind die Bedingungen bezüglich des Straßenbelags homogen und vergleichbar mit denen der Messdatenaufnahme zur Systemmodellierung respektive zum Anlernen des datengetriebenen Ansatzes. Im realen Einsatz treten solche Manöver eher selten auf, es soll jedoch gezeigt werden, dass die entwickelten Methoden auch dafür zureichende Genauigkeiten aufweisen. Anschließend erfolgt eine dem Serieneinsatz nähere Validierung mit Manövern im öffentlichen Straßenverkehr. Darüber hinaus wird ein Vergleich der Methoden bzgl. des Rechenaufwands betrachtet, welcher auf der für die experimentelle Validierung verwendeten prototypischen Hardware aufgebracht wird.

6.3.1 Höherdynamische Manöver auf der Teststrecke

Zur Validierung werden auf der Teststrecke 11 verschiedene Manöver mit Dauern von ca. 65 s bis 260 s betrachtet. Darunter finden sich enge Wendemanöver bei niedrigen Geschwindigkeiten unter 5 km h^{-1} , Lenkwinkelrampen mit stetig zunehmendem Lenkwinkel, sinusartige Lenkbewegungen mit variierenden Amplituden und Frequenzen sowie willkürliche Lenkbewegungen mit ebenfalls variablen Geschwindigkeiten und Lenkwinkelbewegungen wieder. Einen Überblick zu den Ergebnissen verschaffen die Kastendiagramme in Bild 6.3. In der oberen Zeile ist das Resultat der Reifenquerkraftschätzung der ersten Sattelaufliegerachse zu sehen. Die beiden KF weisen sehr ähnliche Schätzgüten auf, der Median des RSME liegt bei etwa 2,39 kN. Das KNN kann mit einem im Median deutlich niedrigeren Fehler von 1,86 kN überzeugen, allerdings liegt der maximal auftretende Fehler mit 2,96 kN in einem sehr ähnlichen Bereich wie bei den KF. Im Minimum weist das KNN ebenfalls einen um ca. 0,4 kN geringeren Fehler auf. Für die Knickwinkelschätzung in der unteren Zeile von Bild 6.3 zeigt sich ein etwas deutlicherer Unterschied zwischen den KF. Bei ähnlichen Minimal- und Maximalwerten weist das UKF mit 1,41° einen geringeren Median des RMSE als das EKF mit 1,72° auf. Das KNN ist den KF erneut in Minimum, Maximum und Median des Fehler mit RMSEs von 0,5°, 3,22° und 1,31° überlegen.

Ein ausgewähltes Manöver aus den 11 Testmanövern ist in Bild 6.4 dargestellt. Es handelt sich um einen sehr eng gefahrenen Slalom mit absoluten Lenkradwinkeln bis über 720° bei ca. 2 m s^{-1} , gefolgt von mehreren Wendemanövern. Dieses Manöver führt zu Knickwinkeln bis zu 60° und Reifenquerkräften an der ersten Achse von nahezu 40 kN. Auch für dieses extreme Manöver, bei dem die Reifen des Sattelaufliegers deutlich erkennbare Kautschukteile verlieren, liefern alle drei Ansätze zufriedenstellende Ergebnisse, welche sich in ihrer Güte kaum unterscheiden. Zu hinterfragen bleibt die Korrektheit der Messung des Knickwinkels im Bereich zwischen ca. 105 s und 115 s. Der Lenkradwinkel ist in dieser Zeit ungefähr in Nullstellung bei einer Geschwindigkeit von ungefähr 5 m s^{-1} . Logischerweise müsste der Knickwinkel an dieser Stelle gegen Null streben, was allerdings nicht der Fall ist. Die genaue Ursache dafür ist nicht bekannt.

Nachdem in diesem Abschnitt die Validierung der Methoden anhand höherdynamischer Manöver auf einer Teststrecke gezeigt wurde, folgt im nächsten Abschnitt die Validierung anhand typischer querdynamischer Manöver im öffentlichen Straßenverkehr.

6.3.2 Öffentlicher Straßenverkehr

Die vorgestellten Methoden wurde bis hierher auf der Teststrecke entwickelt und getestet. Für eine möglichst realitätsnahe Untersuchung werden in diesem Abschnitt Schätzergebnisse auf Testmanöver im öffentlich Straßenverkehr betrachtet, ohne dass Messungen dieser Art in die Entwicklung der Methoden eingeflossen sind. Dafür wurden aus mehrstündigen Messfahrten mit dem Versuchsträger aus Abschnitt 4.2.1 86 charakteristische querdynamische Teilmanöver extrahiert und als Bewertungsgrundlage herangezogen. Einige Beispiele für die betrachteten Teilmanöver sind in Bild 6.5 zu sehen. Es handelt sich dabei um typische Kreiseldurchfahrten mit verschiedenen Ausfahrten sowie unterschiedlichen Kreiselgrößen, Abbiegemanöver mit unterschiedlichen Winkeln und Richtungen, kurvige Landstraßen bei verschiedenen Geschwindigkeiten und Ortsdurchfahrten mit variierendem Verkehrsaufkommen.



Bild 6.3: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für das reale Versuchsfahrzeug anhand von höherdynamischen Manövern auf der Teststrecke.

Eine Zusammenfassung der Ergebnisse ist in Bild 6.6 dargestellt. Auf den ersten Blick weisen alle drei Schätzer ein ähnliches Ergebnis auf. Bei genauerer Betrachtung der Reifenquerkraftschätzung ist zu erkennen, dass das KNN mit einem Median des RMSE von 1,83 kN etwas unter dem der KF mit einem Median von ungefähr 1,94 kN liegt. Auch der maximal auftretenden Fehler liegt beim KNN mit 7,01 kN etwas unter dem höchsten Fehler der KF mit 7,81 kN. Selbiges gilt für den minimal auftretenden Fehler. Für die Reifenquerkräfte ist im Vergleich zwischen EKF und UKF nahezu kein Unterschied erkennbar. Auch für die Schätzung des Knickwinkels zeigt sich bei detaillierter Betrachtung eine leichte Überlegenheit des KNN gegenüber den KF. Der Fehler liegt im Median für das KNN bei 0,68°, während die KF einen Fehler im Median von 0,89° aufweisen. Den größten Fehler weist das EKF mit 4,3° auf, an dieser Stelle erweist sich das UKF mit einem maximalen Fehler von 3,83° als etwas robuster. Das KNN übertrifft in diesem Kriterium erneut die KF mit einem maximalen RMSE von 2,78°. Der minimale Fehler liegt für alle drei Schätzer bei etwas über 0,3°. Im Vergleich zu den Ergebnissen auf der Teststrecke sind grundsätzlich ähnliche Werte zu beobachten. Auffällig ist, dass im öffentlichen Straßenverkehr größere maximale Fehler auftreten, was auf verhältnismäßig kürzere Manöver und inhomogenere und vom Trainingsdatensatz auf der Teststrecke stärker abweichende Verhältnisse zurückzuführen ist.

Eine tiefer gehende Analyse der Schätzergebnisse ermöglicht Bild 6.7. Dargestellt ist der zeitliche Verlauf der gemessenen und der geschätzten Größen für eine Kreiseldurchfahrt, welche repräsentativ für das Gesamtergebnis aus Bild 6.6 steht. Für die Schätzung des Knickwinkels θ und der Reifenquerkraft $F_{y_{21}}$ ergeben sich für die KF sehr ähnliche RMSE von ungefähr 1,17° bzw. 1,67 kN, dabei ist der Graph des EKF in blau unter dem Verlauf des UKF in orange kaum auszumachen. Das KNN weist für dieses Manöver entsprechend des Gesamtresultats deutlich geringere RMSE von 0,42° respektive 1,25 kN auf. Bei der Schätzung des Lenkradwinkels δ_L durch die KF wird aufgrund des verhältnismäßig kurzen Manövers mit einer Gesamtdauer von ungefähr 18 s der auftretenden Zeitverzug besonders deutlich. Dieser ist darauf zurückzuführen, dass kausal der Lenk-


Bild 6.4: Vergleich der Methoden zur Zustandsschätzung am realen Versuchsfahrzeug anhand eines engen Slaloms gefolgt von einigen Wendemanövern. Dargestellt sind die Schätzergebnisse für die Zielgrößen Knickwinkel und Reifenquerkraft an der ersten Achse im Sattelauflieger, welche von allen Methoden geschätzt werden. Zusätzlich findet innerhalb der KF eine Schätzung der unbekannten Eingangsgröße Lenkradwinkel δ_L statt.

winkel als Eingangsgröße die verzögerte Änderung der Zustandsgrößen hervorruft, die Schätzung aber auf der Messung der Zustände basiert und somit erst erfolgen kann, wenn eine signifikante Zustandsgrößenänderung auftritt. An dieser Stelle sei erneut erwähnt, dass eine explizite Schätzung des Lenkwinkels unter Anwendung des KNN nicht nötig, aber durchaus möglich ist. Wird das experimentelle Ergebnis mit dem simulativen aus Abschnitt 5.3 verglichen, ist festzustellen, dass die Verläufe der Schätzgrößen sowie der gemessenen Größen im Vergleich zu den simulierten erkennbar glatter ausfallen. Grund dafür ist die Wahl der im Simulationsmodell beaufschlagten Rauschterme Q_{Sim} und R_{Sim} (vgl. Kapitel 5). Für eine möglichst realitätsnahe Untersuchung in der Simulation werden die Rauschterme darin so gewählt, dass sie den in diesem Kapitel eingestellten



(a) Kreisel



(b) Wenden im Kreisel



(c) Abbiegen



(d) Kurvige Landstraße



Werten für die Filter im experimentellen Versuch (vgl. Abschnitt 6.1) entsprechen. Zu beachten ist allerdings, dass bei nicht exakter Modellierung des zugrundeliegenden Systems innerhalb der Filter, was in der Regel bei realen Systemen der Fall ist, der verbleibende Restfehler des Modells durch ein größer angenommenes Prozessrauschen Berücksichtigung findet, als es im realen System tatsächlich vorliegt. Dies verhilft letztendlich zu einer zufriedenstellenden Performanz im Experiment, führt jedoch tendenziell zu einem zu groß angenommenen stochastischen Prozessrauschanteil in der Simulation. Da für eine Quantifizierung des Prozessrauschen kein trivialer Lösungsweg besteht, erscheint das gewählte Vorgehen als angemessen.

Ein weiteres Manöver mit enormer Belastung für das Fahrwerk ist in Bild 6.8 dargestellt. Hierbei handelt es sich um ein enges Wenden, welches in ähnlicher Form im Serienbetrieb beispielsweise auf Raststätten oder auf Werkshöfen von Speditionen vorkommt. Der Knickwinkel erreicht hierbei im Betrag ein Maximum von um die 60°, während die Messung der Reifenquerkräfte betragsmäßig



Bild 6.6: Vergleich der Schätzer anhand der RMSE bezogen auf die Zielgrößen Reifenquerkraft der ersten Sattelaufliegerachse $F_{y_{21}}$ und Knickwinkel θ für das reale Versuchsfahrzeug anhand typischer querdynamischer Manöver im öffentlichen Straßenverkehr.

an die 40 kN erreichen. Auch für dieses extreme Manöver zeigt sich für den Knickwinkel ein ähnlich zufriedenstellendes Ergebnis durch alle Schätzer wie bei der vorhergegangenen Kreiseldurchfahrt. Die Schätzung der Reifenquerkraft weist im Bereich zwischen 20–30 s insbesondere für die KF signifikante Defizite auf. Diese unterschätzen betragsmäßig die auftretenden Reifenquerkräfte deutlich, was auf eine ungeeignete Parametrierung des Modells in diesem Arbeitspunkt oder eine unzureichende Modellierungstiefe zurückzuführen ist, welche hier auftretende Effekte nicht berücksichtigt. Dies könnten beispielsweise unterschiedliche Effekte des vermutlich nichtlinearen Verhaltens der Luftfederung und des Fahrwerks sein. Ein Verbesserung wäre durch eine Erweiterung des Modells zu erwarten, dies erfordert allerdings umfangreiches domänenspezifisches Wissen und erschwert die Parametrierung des erweiterten Modells. Außerdem erhöht sich damit der Rechenaufwand mit negativer Auswirkung auf die Echtzeitfähigkeit. Das KNN liefert im Vergleich zu den KF, welche einen RMSE von ca. 7,56 kN aufweisen, ein deutlich besseres Ergebnis mit einem RMSE von 3,95 kN. Auch hier ist zwischen 20-30 s eine zwar geringere, aber weiterhin deutliche Abweichung von der Messung zu erkennen. Dies ist auf unzureichende Trainingsdaten in diesem Arbeitsbereich zurückzuführen und sollte ohne großen Aufwand durch die Erweiterung des Datensatzes um Manöver in diesem Bereich zu verbessern sein.

Neben der Betrachtung der Genauigkeiten ist hinsichtlich einer potenzielle Anwendung in einem Serienfahrzeug der Rechenaufwand der verwendeten Algorithmen zu untersuchen. Ziel des nachfolgenden Abschnitts ist es daher, eine Abschätzung über die Rechenintensität der einzelnen Methoden liefern zu können.

6.3.3 Analyse des Rechenaufwands

Zur Untersuchung der Rechenintensität der betrachteten Methoden werden diese auf dem in Abschnitt 4.2.1 beschriebenen Prototypingmodul ES 910 der Firma ETAS implementiert und in



Bild 6.7: Vergleich der Methoden zur Zustandsschätzung im Experiment anhand einer Kreiseldurchfahrt. Dargestellt sind die Schätzergebnisse für die Zielgrößen Knickwinkel und Reifenquerkraft an der ersten Achse im Sattelauflieger, welche von den vorgestellten Methoden geschätzt werden. Zusätzlich findet innerhalb der KF eine Schätzung der unbekannten Eingangsgröße Lenkradwinkel δ_L statt.

Echtzeit getestet. Das Vorgehen ist dabei für alle Methoden gleich. Es wird automatisiert ein echtzeitfähiger C-Code erstellt, welcher die Funktion der jeweiligen Methode abbildet, und auf das Prototypingmodul geladen. Über den CAN Bus nach ISO 11992 (ebenfalls in Abschnitt 4.2.1 beschrieben) greift die Funktion auf dem Prototypingmodul auf die erforderlichen Signale Fahrzeuglängsgeschwindigkeit des Sattelaufliegers v_{x_2} und Raddrehzahldifferenz Δv zwischen linkem und rechtem Rad der mittleren Sattelaufliegerachse zu und berechnet auf Grundlage dieser die Zielgrößen. Die Ausführung der Funktion auf dem Prototypingmodul erfolgt zyklisch in einem vorher festgelegten Takt, welcher in diesem Fall zu 10 ms gewählt wurde und sowohl der Diskretisierungsschrittweite des Sattelzugquerdynamikmodells aus Kapitel 4 als auch der über den CAN



Bild 6.8: Vergleich der Methoden zur Zustandsschätzung im Experiment anhand eines Wendemanövers auf einem Hof. Dargestellt sind die Schätzergebnisse für die Zielgrößen Knickwinkel und Reifenquerkraft an der ersten Achse im Sattelauflieger, welche von den vorgestellten Methoden geschätzt werden. Zusätzlich findet innerhalb der KF eine Schätzung der unbekannten Eingangsgröße Lenkradwinkel δ_L statt.

Bus kommunizierten Senderate der verwendeten Signale entspricht. Zum Vergleich der Rechenzeit wird für jede Methode das gleiche Manöver mit sinusartiger Lenkwinkelanregung gefahren, grundsätzlich zeigen weitere Untersuchungen für andere Manöver vergleichbare qualitative Ergebnisse und weisen somit auf keine signifikante Korrelation zwischen bestimmten Manövern und der Rechenintensität hin. Das Prototypingmodul erlaubt durch eine interne Funktion das Monitoring der Rechendauer für einen Rechentakt. Diese wird zum Grundtakt von 10 ms ins Verhältnis gesetzt und ergibt somit eine Auslastung des Moduls in Prozent.

Die Ergebnisse des Rechenaufwands sind in Bild 6.9 für eine Laufzeit von 30 s dargestellt. Es ist zu erkennen, dass das KNN mit einer durchschnittlichen Auslastung von 0.67 % den geringsten

Rechenaufwand aufweist. Das EKF weist einen etwas höheren Rechenbedarf von durchschnittlich 1,65% Auslastung auf. Am rechenintensivsten ist das UKF mit einer mittleren Auslastung von 5,61%, was ungefähr dem achtfachen der Auslastung mit dem KNN entspricht. Für alle drei Methoden sind immer wieder auftretenden Auslastungsspitzen zu beobachten, deren Ursache unbekannt bleibt. Besonders stark ausgeprägt sind diese beim UKF. Einige Spitzen erreichen sogar eine Auslastung von knapp über 55%, welche aus Darstellungsgründen im Bild nicht gänzlich zu sehen sind. Fraglich ist im Hinblick auf eine potenzielle Seriensensorik mit mutmaßlich geringerer Rechenkapazität, ob diese anhand der Spitzen ausgelegt werden muss oder ob Lastspitzen solcher Art unproblematisch sind bzw. anderweitig berücksichtigt werden können.

Zusammenfassend lässt sich feststellen, dass alle Methoden problemlos auf dem Prototypenmodul ausgeführt werden können, wobei das KNN den geringsten Rechenaufwand aufweist. Aus der Literatur sind weitere Untersuchungen zum Vergleich des Rechenaufwands modellbasierter und datengetriebener Methoden mit ähnlichen Ergebnissen bekannt. In [LK18] wird beispielsweise ein nichtlinearer modellprädiktiver Regler durch einen weitaus recheneffizienteren datengetriebenen Ansatz gleicher Güte ersetzt. Die Eignung für den echtzeitfähigen Serieneinsatz der Methoden im Sattelzug lässt sich ohne die Kenntnis über die Performanz einer serienmäßigen Zielhardware nur bedingt zeigen. Vielmehr ist das Ergebnis als Vergleich unter den Ansätzen zu deuten und lässt eine Favorisierung des KNN zu, insbesondere wenn an die simultane Schätzung mehrerer Größen auf einer, möglichst kostengünstigen Hardware abgezielt wird.



Bild 6.9: Vergleich der betrachteten Methoden hinsichtlich ihrer Rechenintensität basierend auf der Auslastung des Prototyping Moduls ETAS ES 910.

6.4 Fazit

In diesem Kapitel wurden die zuvor in Kapitel 5 anhand des Simulationsmodells umgesetzten und analysierten Methoden auf den realen Versuchsträger angewendet und validiert. Dies erlaubt eine realistischere Beurteilung der Methoden im tatsächlichen Einsatz, limitiert allerdings auf Grund des damit einhergehenden Aufwands auch die Möglichkeiten zur Betrachtung verschiedener Einflussgrößen auf die erarbeiteten Schätzalgorithmen.

Das Vorgehen zur Entwicklung der modellbasierten und datenbasierten Zustandsschätzung gleicht im Wesentlichen dem der simulativen Untersuchungen, nur dass an Stelle des Simulationsmodells das reale Versuchsfahrzeug tritt. Dies führt dazu, dass beispielsweise die Prozessrauschkovarianzen im Gegensatz zum Simulationsmodell weder bekannt, noch direkt messbar sind und empirisch eingestellt wurden. Nach detaillierter Erläuterung der Änderungen im Vergleich zu den simulativen Untersuchungen wurden die betrachteten Ansätze online auf einer prototypischen Hardware (ETAS ES 910) implementiert und getestet. Die Tests wurden unterteilt in Untersuchungen auf einer Teststrecke, welche auch zur Messdatenaufnahme zwecks Systemmodellierung und Parameteridentifikation sowie Trainingsdatengenerierung befahren wurde, und in Untersuchungen im öffentlichen Straßenverkehr. Anschließend wurde ein Augenmerk auf den Vergleich des benötigten Rechenaufwands gelegt.

Es lässt sich zusammenfassen, dass im Gegensatz zur Simulation die Ergebnisse des KNN im Vergleich zu denen der KF besser sind. Dies ist zum einen darauf zurückzuführen, dass die den KF zugrundeliegenden Modelle nicht mehr exakt mit dem beobachteten System übereinstimmen. Darüber hinaus stimmt im realen Fahrversuch das angenommene Prozessrauschen in der Regel nicht exakt mit dem tatsächlichen Prozessrauschen überein und ist ebenfalls problematisch für eine optimale Performanz der KF. Das KNN scheint hingegen in der Lage zu sein, das Systemverhalten und die Prozess- sowie Messrauschvarianzen auf Basis der Trainingsdaten in einer solchen Qualität anzulernen, dass es schließlich zu einer ggü. den KF leicht überlegenen Schätzgüte führt. Hinsichtlich der Echtzeitfähigkeit und des Rechenaufwands zeigt sich, dass alle Ansätze problemlos auf der prototypischen Hardware ausführbar sind, doch auch hier das KNN durchschnittlich weniger als die Hälfte an Rechenaufwand ggü. dem EKF und sogar nur ein Achtel ggü. dem UKF aufweist. Somit ergibt sich abschließend, dass KNN als Zustandsschätzer durchaus eine attraktive Alternative zu den bisher überwiegend eingesetzten modellbasierten Ansätzen sein kann. Ein ausführliches Resümee zu den Inhalten dieser Arbeit folgt im abschließenden Kapitel.

7 Zusammenfassung und Ausblick

In Serie produzierte PKW weisen eine immer höhere Anzahl an Sensoren, Aktoren und Recheneinheiten auf. Dies ermöglicht, es eine Vielzahl von FAS umzusetzen. Das führt zu einer gesteigerten Fahrsicherheit für die Insassen sowie andere Verkehrsteilnehmer und zur Entlastung der fahrzeugführenden Person. Der zunehmende Eingriff solcher Systeme in den Aufgabenbereich des Menschen als zentrale Regeleinheit erlaubt bei Gewährleistung der Einhaltung der Straßenverkehrsordnung einen teilautonomen bis hin zum völlig autonomen Betrieb des Fahrzeugs. FAS sind häufig auf die genaue Erfassung der aktuellen fahrdynamischen Zustände angewiesen, um daraus die entsprechenden Eingriffe abzuleiten. Kenntnisse über diese Zustände können teilweise über eine direkte Messung erhalten werden, für einige Zustände lässt sich die Messung im Serienfahrzeug jedoch beispielsweise aufgrund zu hoher Kosten nicht realisieren. Dieser Problematik ist beispielsweise über eine indirekte Schätzung solcher Zustände zu begegnen.

Die Zustandsschätzung in PKW ist umfangreich in der bestehenden Literatur beschrieben und findet bereits Eingang in Serienfahrzeuge. Dabei lassen sich modellbasierte und datenbasierte Ansätze unterscheiden. Modellbasierte Methoden werden häufiger und bereits seit längerer Zeit in Betracht gezogen, sie führen die Schätzung auf Grundlage eines physikalischen Modells und der verfügbaren Messgrößen durch. Im Gegensatz dazu erfreuen sich in jüngster Vergangenheit datenbasierte Ansätze immer größerer Beliebtheit, welche die Zustandsschätzung rein auf Basis vorhandener Daten erlernen. Trotz z.T. sehr guter Ergebnisse ist deren Serienanwendung, begründet durch unzureichende Erfahrungswerte bzgl. Robustheit, Stabilität oder Übertragbarkeit etc., ungewiss und erfordert weitergehende Untersuchungen.

Im Bezug auf Sattelzüge, als Vertreter aus dem NFZ-Bereich, liegt eine gänzlich andere Situation vor. Dabei weist die Zugmaschine bzgl. der Ausstattung mit FAS gegenüber dem üblichen Sattelauflieger im Feld, welcher bis auf ein EBS meistens keinerlei weitere FAS aufweist, einen deutlich höheren technischen Reifegrad auf. Dies lässt den Auflieger potenziell zum Hindernis bei der Entwicklung des autonom fahrenden Sattelzugs werden. Um dies zu vermeiden, ist die Entwicklung intelligenter Systeme für den Sattelauflieger unter Berücksichtigung der besonderen Gegebenheiten (u.a. häufig wechselnde Zugmaschine, fehlende Kommunikation zur Zugmaschine, stark variierende Beladung und hoher Kostendruck) essenziell. Ein wichtiger Schritt dafür ist die Bereitstellung relevanter, im Serienfahrzeug nicht messbarer Zustandsgrößen auf Basis der vorhandenen Seriensensorik. Dazu bieten sich, wie zuvor für PKW beschrieben, modellbasierte und datenbasierte Methoden der Zustandsschätzung an. Für beide Ansätze finden sich in der bestehenden Literatur nur wenige Vorarbeiten wieder, die den Serienanforderungen im Sattelzug gerecht werden, was besonders für den datenbasierten Ansatz zutrifft. Darüber hinaus bleibt ein direkter Vergleich der Ansätze bislang aus.

7.1 Zusammenfassung

In der vorliegenden Arbeit werden am Beispiel des Sattelaufliegers modell- und datenbasierte Ansätze zur Zustandsschätzung umgesetzt, untersucht und verglichen, um einerseits mögliche Lösungsansätze für die zuvor beschriebene Problematik anzubieten und andererseits grundlegende Erkenntnisse zum Einsatz der beiden Alternativen abzuleiten. Dazu wird in Kapitel 1 zunächst eine Einleitung in die Thematik gegeben, die auf ein Verständnis für die Relevanz der ausgewählten Zielgrößen, den Knickwinkel und die Reifenquerkräfte, für die Zustandsschätzung im Sattelauflieger abzielt. Anschließend wird eine Übersicht zum Stand des Wissens vermittelt, um die Zielsetzung und die Inhalte der Arbeit darin verorten zu können.

In Kapitel 2 werden zunächst unabhängig von einem konkreten Anwendungsfall die Grundlagen zur modellbasierten Zustandsschätzung beschrieben. Nach den generell erforderlichen Bedingungen werden daraufhin zwei ausgewählte Methoden, das EKF und das UKF, detailliert erläutert. Da im Rahmen der modellbasierten Zustandsschätzung in der Anwendung am Sattelauflieger, aufgrund der nicht vorhandenen Kommunikation zur Zugmaschine, eine Eingangsschätzung erforderlich ist, schließt sich die Beschreibung einer dafür erforderlichen Erweiterung an. Abschließend wird die praktische Auslegung und Einstellung dargestellt.

Analog zum Kapitel 2 beinhaltet Kapitel 3 die Grundlagen zur datenbasierten Zustandsschätzung, wobei eine Begrenzung auf KNN erfolgt. Als Vertreter aus diesem Bereich wird das NARX-KNN gewählt und detailliert beschrieben. Es folgen die für den datenbasierten Ansatz erforderlichen Lernverfahren und die Datensatzaufbereitung. Zum Schluss wird das Vorgehen zur Auslegung des KNN für einen konkrete Anwendung erörtert.

Als Grundlage für den modellbasierten Ansatz und die im Kapitel 5 durchgeführten simulativen Untersuchungen dient das in Kapitel 4 erarbeitete Querdynamikmodell des Sattelzugs. Die Beschreibung der Systemmodellierung und Parameteridentifikation beginnt mit einer Definition der verwendeten Koordinatensysteme und einer durch Vorarbeiten aus der Literatur begründeten Wahl der Modellierungstiefe. Als geeignetes Modell stellt sich ein nichtlineares Einspurmodell mit nichtlinearer Reifen-Fahrbahn Charakteristik nach dem MFTM heraus, dessen Bewegungsgleichungen sukzessive hergeleitet werden. Das entstandene Querdynamikmodell mit 10 Zuständen beinhaltet eine Vielzahl von Modellparametern, die es hinsichtlich des Versuchsfahrzeuges zu parametrieren gilt. Dazu wird zunächst das verwendete Versuchsfahrzeug und dessen serienmäßig vorhandene Sensorik sowie die im experimentellen Aufbau zusätzlich eingesetzte, jedoch lediglich zur Validierung verwendete Sensorik beschrieben. Es schließt sich der Parametrierungsablauf an, welcher sich in bekannte bzw. leicht durch Vermessung zu bestimmende Parameter (z.B. geometrische Längen, Massen) und durch eine Parameteridentifikation zu bestimmende Parameter aufteilt. Zur Parameteridentifikation werden Messdaten ausgewählter Manöver herangezogen und das Modell hinsichtlich seiner Parameter durch eine PSO angepasst, sodass die Abweichung zwischen wahrer Messung und den Modellausgängen möglichst minimal wird. Das Kapitel schließt mit einer experimentellen Validierung des Modells ab. Dabei zeigt sich eine gute Übereinstimmung zwischen den simulierten und gemessenen Größen für unterschiedliche Fahrsituationen und Beladungszustände.

In Kapitel 5 kommt es zur Anwendung der zuvor in ihren Grundlagen erläuterten Methoden anhand des ebenfalls zuvor vorgestellten Simulationsmodells. Dabei wird zunächst auf den modellbasierten Ansatz eingegangen, der im ersten Schritt optimal eingestellt wird, d.h. das Modell innerhalb der KF stimmt in seiner Struktur und seinen Parametern exakt mit dem Simulationsmodell überein. Außerdem werden die Kovarianzen für die Einstellung im Filter als exakt bekannt angenommen. Anschließend wird das Vorgehen für den datenbasierten Ansatz beschrieben. Für einen angemessenen Vergleich werden simulative Trainingsdaten unter den gleichen Modelleinstellungen wie im späteren Test aufgenommen und anhand dessen das KNN trainiert und ausgelegt. Ein Vergleich zwischen den modellbasierten und der datenbasierten Methode unter diesen idealisierten Bedingungen zeigt grundsätzlich für alle Ansätze eine hohe Schätzgüte. Bei der Schätzung der Reifenquerkraft sind die modellbasierten Methoden dem KNN leicht überlegen, wohingegen das KNN den Knickwinkel marginal besser abbildet. Nach der Betrachtung unter idealen Voraussetzungen werden einzelne Parameter des Simulationsmodells variiert und der Einfluss auf die Schätzgüte der Methoden untersucht. Dazu gehören das Prozessrauschen, die Masse des Sattelaufliegers, die Position des Schwerpunkts im Sattelauflieger sowie der Reibwert und die Parameter zur Charakterisierung des Reifenverhaltens. Zusammenfassend lässt sich festhalten, dass alle Methoden bei Abweichung vom idealisierten Fall in ähnlicher Größenordnung an Genauigkeit verlieren. Dabei ist für die Reifenquerkräfte bei zunehmender Abweichung ein geringerer Unterschied unter den Ansätzen zu beobachten. Im Vergleich zum Knickwinkel ist die Schätzung der Reifenquerkraft deutlich stärker von einer abweichenden Parametrierung betroffen. Dies ist darauf zurückzuführen, dass es sich bei der Reifenquerkraft um eine dynamische und beim Knickwinkel um eine kinematische Größe handelt.

Die Erkenntnisse aus den simulativen Untersuchungen werden in Kapitel 6 auf das reale Versuchsfahrzeug übertragen. Die Auslegung und Einstellung der modellbasierten und der datenbasierten Methoden erfolgen analog zur Simulation, an Stelle des Simulationsmodells tritt hier das Versuchsfahrzeug. Die entwickelten Algorithmen werden in Echtzeit auf einer prototypischen Hardware ausgeführt. Die experimentellen Ergebnisse unterteilen sich in zwei Teile. Zunächst werden auf einer Teststrecke höherdynamische Manöver evaluiert, die vermehrt die Nichtlinearitäten des Systems durchlaufen. Dabei zeigt sich im Gegensatz zur Simulation für beide Zielgrößen eine Überlegenheit des KNN. Dies ist darauf zurückzuführen, dass KNN sehr ausgeprägte Fähigkeiten in der Abbildung komplexer, nichtlineare Zusammenhänge haben und das bei verhältnismäßig einfachen Netzarchitekturen. Für eine verbesserte modellbasierte Schätzung wäre ein höherer Detailgrad des innerhalb der Methoden verwendeten Modells erforderlich, was jedoch zur erhöhten Modellierungs-, Parametrierungs- und Rechenaufwand führt. Der zweite Teil der experimentellen Validierung erfolgt anhand von Manövern im öffentlichen Straßenverkehr, um die Relevanz der Untersuchungen für den realitätsnahen Anwendungsbereich zu erhöhen. Das KNN ist den modellbasierten Ansätzen auch für diesen Fall überlegen, allerdings nicht so deutlich wie bei den höherdynamischen Manövern auf der Teststrecke. Ein Vergleich des Rechenaufwands zeigt, dass das KNN weniger Ressourcen als die modellbasierten Methoden in Anspruch nimmt. Dies bekräftigt das abschließende Fazit, welches empfiehlt, für zukünftige Problemstellungen der echtzeitfähige Zustandsschätzung im Fahrzeug datenbasierte Ansätze vermehrt als mögliche Alternative in Betracht zu ziehen.

7.2 Ausblick

Der Fokus dieser Arbeit liegt auf der separaten Betrachtung von modellbasierten- und datenbasierten Ansätzen zur Zustandsschätzung im Fahrzeug am Beispiel des Sattelzugs. In weiterführenden Arbeiten am Institut für Mechatronische Systeme der Leibniz Universität Hannover werden darüber hinaus optimale Kombinationsmöglichkeiten beider Ansätze zur Zustandsschätzung, aber auch zur Modellierung und Regelung betrachtet. Dadurch können potenziell die Stärken beider Methoden ausgenutzt und die Schwächen minimiert werden. Im universitätsintern durch die Leibniz Young Investigator Grants geförderten Projekt Physikalische Modellierung & Maschinelles Lernen: Symbiose zur Optimierung mechatronischer Systeme (kurz: SyMoLearn) werden dabei als Versuchsträger ein inverses Doppelpendel und ein PKW betrachtet. Erste Ergebnisse sind in [ZKJ22] veröffentlicht worden. Des Weiteren stellen die Erkenntnisse dieser Arbeit eine Grundlage für den Online-Zwilling im Projekt IdenT - Identifikation dynamik- und sicherheitsrelevanter Trailerzustände für automatisiert fahrende Lastkraftwagen, welches vom Bundesministerium für Wirtschaft und Klimaschutz gefördert wird. Im Rahmen des Projekts werden weiterführend experimentelle Untersuchungen zur Robustheit der Schätzmethoden bezüglich Parameteränderungen und zur Adaption der variierenden Parameter vorgenommen. Beispielsweise können für die Adaption der Sattelaufliegermasse Informationen des Luftfedersystems einbezogen werden.

Offen bleibt die Fragestellung, wie übertragbar die Methoden, besonders die datenbasierten Ansätze, auf andere Sattelzüge oder gar andere Fahrzeugtypen sind und welche Anpassungen dafür notwendig sind. Außerdem gilt es, die erarbeiteten Methoden in umfangreichen Testfahrten des Serienbetriebs zu erproben. Dabei wird vermutlich die Berücksichtigung weiterer sensitiver Parameter erforderlich, die eine hohe Sensitivität auf die Zustandsschätzung aufweisen, wie beispielsweise der Reibwert. Darüber hinaus sollte die Konfidenz der Schätzungen evaluiert werden, welche sich bei Bedarf durch Fusion weiterer Informationen erhöhen ließe. Nach erfolgreichem Abschluss dieser Untersuchungen können die Zielgrößen z.B. im Rahmen einer übergeordneten Regelung, einem Condition Monitoring oder zur Umsetzung eines Predicitve Maintanence Ansatzes verwendet werden.

Literaturverzeichnis

Während der Promotion am Institut für Mechatronische Systeme wurden Zwischenergebnisse dieser Arbeit sowie verwandte wissenschaftliche Ergebnisse auf internationalen Konferenzen veröffentlicht. Diese sind im folgenden Literaturverzeichnis aufgeführt. Allgemeine Literatur ist im daran anschließenden Verzeichnis zu finden.

Eigene Publikationen

- [JZK⁺20] T. Jahn, Z. Ziaukas, J.-P. Kobler, M. Wielitzka und T. Ortmaier. "Neural Observer for Nonlinear State and Input Estimation in a Truck-Semitrailer Combination". In: 21st IFAC World Congress (2020).
- [ZBW21] Z. Ziaukas, A. Busch und M. Wielitzka. "Estimation of Vehicle Side-Slip Angle at Varying Road Friction Coefficients Using a Recurrent Artificial Neural Network". In: *Conference on Control Technology and Applications (CCTA)* (2021), S. 986–991.
- [ZKB⁺19] Z. Ziaukas, J.-P. Kobler, A. Busch, M. Wielitzka und T. Ortmaier. "Nonlinear Modeling of Truck-Semitrailer Lateral Dynamics Including Experimental Validation of Lateral Tire Forces". In: *The IAVSD International Symposium on Dynamics of Vehicles on Roads and Tracks* (2019), S. 1879–1888.
- [ZKB⁺20] Z. Ziaukas, J.-P. Kobler, A. Busch, M. Wielitzka und T. Ortmaier. "Classification of Tire Pressure in a Semitrailer Using a Convolutional Neural Network". In: *International Conference on Mechatronics and Automation (ICMA)* (2020), S. 181–185.
- [ZKJ22] Z. Ziaukas, L. Kemper und H.-G. Jacob. "Hybrid State Estimation at Varying Road Friction Coefficients Combining LSTM-NN and UKF". In: *15th International Symposium on Advanced Vehicle Control* (2022).
- [ZKW⁺19] Z. Ziaukas, J.-P. Kobler, M. Wielitzka und T. Ortmaier. "Simultaneous Estimation of Steering and Articulation Angle in a Truck-Semitrailer Combination Solely Based on Trailer Signals". In: American Control Conference (ACC) (2019).

Allgemeine Literatur

[ACP⁺17] S. E. Azam, E. Chatzi, C. Papadimitriou und A. Smyth. "Experimental validation of the Kalman-type filters for online and real-time state and input estimation". In: *Journal of Vibration and Control* 23.15 (2017), S. 2494–2519.

- [ADE20] Y. Amellas, A. Djebli und A. Echchelh. "Levenberg-Marquardt Training Function using on MLP, RNN and Elman Neural Network to Optimize Hourly Forecasting in Tetouan City (Northern Morocco)". In: Journal of Engineering Science and Technology Review 13.1 (2020), S. 67–71.
- [AG19] H. Ahmadi Jeyed und A. Ghaffari. "Nonlinear estimator design based on extended Kalman filter approach for state estimation of articulated heavy vehicle". In: Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-body Dynamics 233.2 (2019), S. 254–265.
- [Agg18] C. C. Aggarwal. Neural Networks and Deep Learning. Springer International Publishing AG, 2018.
- M. Acosta und S. Kanarachos. "Tire lateral force estimation and grip potential identifi-[AK18] cation using Neural Networks, Extended Kalman Filter, and Recursive Least Squares". In: Neural Computing and Applications 30.11 (2018), S. 3445–3465.
- [Alb13] M. Alberding. "Steering of Semi-Trailer". Dissertation. ETH Zürich, 2013.
- [Arn18] D. Arnström. "State Estimation for Truck and Trailer Systems using Deep Learning". Masterarbeit. Linköping University, 2018.
- [BBG⁺09] M. J. L. Boada, B. L. Boada, D. Garcia-Pozuelo und V. Diaz. "Application of Neural Networks for Estimation of Tyre/Road Forces". In: Proceedings of the ASME 2009 International Mechanical Engineering Congress & Exposition (2009).
- [Bec18] J. P. Bechtloff. "Schätzung des Schwimmwinkels und fahrdynamischer Parameter zur Verbesserung modellbasierter Fahrdynamikregelungen". Dissertation. Technische Universität Darmstadt, 2018.
- [BFT⁺19] A. Bonfitto, S. Feraco, A. Tonoli und N. Amati. "Combined regression and classification artificial neural networks for sideslip angle estimation and road condition identification". In: Vehicle System Dynamics 27.4 (2019), S. 1–22.
- [BHD20] M. Beale, M. T. Hagan und H. Demuth. Deep Learning Toolbox User's Guide. Hrsg. von Mathworks Inc. 2020. URL: https://www.mathworks.com/help/ pdf_doc/deeplearning/nnet_ug.pdf (besucht am 27.11.2020).
- [BNH19] Z. Brock, J. Nelson und R. L. Hatton. "A Comparison of Lateral Dynamic Models for Tractor-Trailer Systems". In: Proceedings of the 2019 IEEE Intelligent Vehicle Symposium (IV) (2019), S. 2052–2059.
- BPW Bergische Achsen KG. Freigegebene unternehmenseigene Abbildungen, Grafi-[BPW21] ken und Logos. 2021.
- [BR15] S. Breuer und A. Rohrbach-Kerl. Fahrzeugdynamik. Mechanik des bewegten Fahrzeugs. Springer Fachmedien Wiesbaden, 2015.

- [BR93] M. Burckhardt und J. Reimpell, Hrsg. *Fahrwerktechnik*. 1. Aufl. Vogel-Fachbuch Kraftfahrzeugtechnik. Würzburg: Vogel, 1993.
- [BXA⁺21] B. H. G. Barbosa, N. Xu, H. Askari und A. Khajepour. "Lateral Force Prediction using Gaussian Process Regression for Intelligent Tire Systems". In: *IEEE Transactions on Systems, Man, and Cybernetics: Systems* (2021).
- [Cal20] O. Calin. *Deep Learning Architectures*. Cham: Springer International Publishing, 2020.
- [CC11] C. Cheng und D. Cebon. "Parameter and state estimation for articulated heavy vehicles". In: *Vehicle System Dynamics* (2011), S. 399–418.
- [CFS⁺10] L. Chu, Y. Fang, M. Shang, J. Guo und F. Zhou. "Estimation of Articulation Angle for Tractor Semi-trailer Based on State Observer". In: *International Conference on Measuring Technology and Mechatronics Automation* (2010), S. 158–163.
- [CG18] D. Chindamo und M. Gadola. "Estimation of Vehicle Side-Slip Angle Using an Artificial Neural Network". In: *MATEC Web of Conferences* 166.3 (2018).
- [CLG18] D. Chindamo, B. Lenzo und M. Gadola. "On the Vehicle Sideslip Angle Estimation: A Literature Review of Methods, Models, and Innovations". In: *Applied Sciences* 8.3 (2018), S. 355.
- [COA+95] C. Canudas de Wit, H. Olsson, K. J. Astrom und P. Lischinsky. "A new model for control of systems with friction". In: *IEEE Transactions on Automatic Control* 40.3 (1995), S. 419–425.
- [CT95] C. Chen und M. Tomizuka. "Dynamic Modeling Of Tractor-semitrailer Vehicles In Automated Highway Systems". In: UC Berkeley: California Partners for Advanced Transportation Technology (1995).
- [CvG⁺14] K. Cho, B. van Merrienboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk und Y. Bengio. "Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation". In: *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (2014), S. 1724–1734.
- [DB04] H. Demuth und M. Beale. Neural Network Toolbox User's Guide. Hrsg. von Mathworks Inc. 2004. URL: http://cda.psych.uiuc.edu/matlab_pdf/ nnet.pdf.
- [DIN13] DIN ISO 8855:2013-11. *Straßenfahrzeuge Fahrzeugdynamik und Fahrverhalten Begriffe*. 2013.
- [DIN19] DIN ISO 11992:2019-05. Straßenfahrzeuge Austausch von digitalen Informationen über elektrische Verbindungen zwischen Zugfahrzeugen und Anhängefahrzeugen. 2019.

[DL16]	J. Dye und H. Lankarani. "Hybrid Simulation of a Dynamic Multibody Vehicle Sus- pension System Using Neural Network Modeling Fit of Tire Data". In: <i>Proceedings</i> <i>of the ASME 2016 International Design Engineering Technical Conferences and</i> <i>Computers and Information in Engineering Conference</i> (2016).
[DLT20]	F. Di Biase, B. Lenzo und F. Timpone. "Vehicle sideslip angle estimation for a heavy- duty vehicle via Extended Kalman Filter using a Rational tyre model". In: <i>IEEE</i> <i>Access</i> (2020), S. 142120–142130.
[DR08]	W. Dahmen und A. Reusken. <i>Numerik für Ingenieure und Naturwissenschaftler</i> . Springer Berlin Heidelberg, 2008.
[DU95]	S. Drakunov und V. Utkin. "Sliding mode observers. Tutorial". In: <i>Proceedings of</i> 1995 34th IEEE Conference on Decision and Control (1995), S. 3376–3378.
[DVC ⁺ 09]	M. Doumiati, A. Victorino, A. Charara und D. Lechner. "Estimation of vehicle lateral tire-road forces: a comparison between extended and unscented Kalman filtering". In: <i>Proceedings of the 2009 European Control Conferene (ECC)</i> (2009).
[FAS04]	 B. Feil, J. Abonyi und F. Szeifert. "Model order selection of nonlinear input–output models—-a clustering based approach". In: <i>Journal of Process Control</i> 14.6 (2004), S. 593–602.
[FB66]	B. Friedland und I. Bernstein. "Estimation of the State of a Nonlinear Process in the Presence of Nongaussian Noise and Disturbances". In: <i>Journal of the Franklin Institute</i> 6 (1966), S. 455–480.
[FH97]	F. D. Foresee und M. Hagan. "Gauss-Newton Approximation to Bayesian Learning". In: <i>Proceedings of International Conference on Neural Networks</i> (1997).
[FKS08]	H. K. Fathy, D. Kang und J. L. Stein. "Online vehicle mass estimation using recursive least squares and supervisory data extraction". In: <i>Proceedings of the 2008 American Control Conference (ACC)</i> (2008), S. 1842–1848.
[GBB11]	X. Glorot, A. Bordes und Y. Bengio. "Deep Sparse Rectifier Neural Networks". In: <i>Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics</i> (2011), S. 315–323.
[Geh00]	O. Gehring. "Automatische Längs- und Querführung einer Lastkraftwagenkolonne". Dissertation. Universität Stuttgart, 2000. 233 S.
[Gip99]	M. Gipser. "FTire, a New Fast Tire Model for Ride Comfort Simulations". In: International ADAMS User's Conference Berlin (1999).
[GJN+20]	T. Ghandriz, B. Jacobson, P. Nilsson, L. Laine und N. Frojd. "Computationally Efficient Nonlinear One- and Two-Track Models for Multitrailer Road Vehicles". In: <i>IEEE Access</i> 8 (2020), S. 203854–203875.

- [GSM⁺00] M. Gäfvert, Sanfridson, M. und V. Claesson. "Truck Model for Yaw Dynamics Control". In: *Internal Report Lund Institute of Technology* (2000).
- [HA93] X. He und H. Asada. "A New Method for Identifying Orders of Input-Output Models for Nonlinear Dynamic Systems". In: *Proceedings of the 1993 American Control Conference (ACC)* (1993), S. 2520–2523.
- [Han16] M. Handreg. "Entwurf von Künstlichen Neuronalen Netzen zur Regelung von Prozessgrößen in einer Schmelzwanne für Flachglas". Dissertation. Technischen Universität Cottbus-Senftenberg, 2016.
- [HBB⁺11] A. M. Hermundstad, K. S. Brown, D. S. Bassett und J. M. Carlson. "Learning, memory, and the role of neural network architecture". In: *PLoS Computational Biology* 7.6 (2011).
- [HG10] E. M. Hendrix und B. G.-Tóth. *Introduction to Nonlinear and Global Optimization*.Bd. 37. Springer New York, 2010. 218 S.
- [HHK⁺22] A. Habibnejad Korayem, E. Hashemi, A. Khajepour und B. Fidan. "Estimation of Vehicle-Trailer Hitch-Forces and Lateral Tire Forces Independent of Trailer Type and Geometry". In: *Journal of Dynamic Systems, Measurement, and Control* (2022).
- [Hil16] M. Hilgers. *Chassis und Achsen*. Wiesbaden: Springer Fachmedien Wiesbaden, 2016.
- [HM94] M. T. Hagan und M. B. Menhaj. "Training feedforward networks with the Marquardt algorithm". In: *IEEE Transactions on Neural Networks* 5.6 (1994), S. 989–993.
- [HS97] S. Hochreiter und J. Schmidhuber. "Long Short-Term Memory". In: *Neural Computation* (1997).
- [IBM⁺14] H. Imine, A. Benallegue, T. Madani und S. Srairi. "Rollover Risk Prediction of Heavy Vehicle Using High-Order Sliding-Mode Observer: Experimental Results". In: *IEEE Transactions on Vehicular Technology* 63.6 (2014), S. 2533–2543.
- [ID08] H. Imine und V. Dolcemascolo. "Sliding mode observers to heavy vehicle vertical forces estimation". In: *International Journal of Heavy Vehicle Systems* 15 (2008), S. 53–64.
- [IM11] R. Isermann und M. Münchhof. *Identification of Dynamic Systems*. Springer Berlin Heidelberg, 2011.
- [INT21] INTRAPLAN Consult GmbH. Gleitenden Mittelfristprognose für den Güter- und Personenverkehr. Mittelfristprognose Winter 2020/21. 2021.
- [Irl16] J. P. Irle. "Analyse und Entwurf von Beobachtern mit unbekannten Signalen und Parametern". Dissertation. Karlsruher Institut für Technologie, 2016.
- [Ise92] R. Isermann. *Identifikation dynamischer Systeme 1. Grundlegende Methoden*. Springer, 1992. 343 S.

1	1	4
---	---	---

[Jin66]	F. Jindra. "Handling Characteristics of Tractor-Trailer Combinations". In: <i>SAE Transactions</i> 74 (1966), S. 378–394.
[JK03]	S. Joe und F. Y. Kuo. "Remark on algorithm 659: Implementing Sobol's quasirandom sequence generator". In: <i>ACM Transactions on Mathematical Software (TOMS)</i> 29 (2003), S. 49–57.
[JK09]	R. K. Jatoth und T. K. Kumar. "Particle Swarm Optimization Based Tuning of Unscented Kalman Filter for Bearings Only Tracking". In: <i>International Conference on Advances in Recent Technologies in Communication and Computing</i> (Kottayam, Kerala, India). IEEE, 2009, S. 444–448.
[JU97]	S. J. Julier und J. K. Uhlmann. "New extension of the Kalman filter to nonlinear systems". In: <i>Proc. SPIE 3068, Signal Processing, Sensor Fusion, and Target Recognition VI</i> (1997).
[Jul02]	S. J. Julier. "The Scaled Unscented Transformation". In: <i>Proceedings of the 2002 American Control Conference (ACC)</i> . IEEE, 2002, S. 4555–4559.
[JYC19]	X. Jin, G. Yin und N. Chen. "Advanced Estimation Techniques for Vehicle System Dynamic State: A Survey". In: <i>Sensors (Basel, Switzerland)</i> 19.19 (2019).
[Kal60]	R. Kalman. "A New Approach to Linear Filtering and Prediction Problems". In: <i>Journal of Basic Engineering</i> 82 (1960), S. 35–45.
[KE95]	J. Kennedy und R. Eberhart. "Particle Swarm Optimization". In: <i>Proceedings of ICNN'95 - International Conference on Neural Networks</i> . IEEE, 1995, S. 1942–1948.
[KID+10]	O. Khemoudj, H. Imine, M. Djemai und L. Fridman. "Variable gain sliding mode observer for heavy duty vehicle tyre forces estimation". In: <i>11th International Workshop on Variable Structure Systems</i> (2010), S. 522–527.
[Kie88]	U. Kiencke. "A view of automotive control systems". In: <i>IEEE Control Systems Magazine</i> 8.4 (1988), S. 11–19.
[KK19]	K. Katanforoosh und D. Kunin. <i>Initializing neural networks</i> . Hrsg. von deeplear- ning.ai. 2019. URL: https://www.deeplearning.ai/ai-notes/ initialization/.
[KLF13]	S. Kharrazi, M. Lidberg und J. Fredriksson. "A generic controller for improving lateral performance of heavy vehicle combinations". In: <i>Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering</i> 227.5 (2013), S. 619–642.
[KN05]	U. Kiencke und L. Nielsen. Automotive control systems. For engine, driveline, and vehicle ; with 13 tables. Berlin: Springer, 2005.

[KNS ⁺ 18]	K. Kandasamy, W. Neiswanger, J. Schneider, B. Póczos und E. P. Xing. "Neural Architecture Search with Bayesian Optimisation and Optimal Transport". In: <i>32nd Conference on Neural Information Processing Systems (NeurIPS 2018)</i> (2018).
[Kol09]	D. Kollreider. "Identifikation der Reifeneigenschaften als Grundlage zur Fahdynamik- bewertung". Dissertation. Technischen Universität Graz, 2009. 148 S.
[Kra21]	Kraftfahrt Bundesamt. Fahrzeugzulassungen (FZ). Bestand an Nutzfahrzeugen, Kraft- fahrzeugen insgesamt und Kraftfahrzeuganhängern nach technischen Daten (Größen- klassen, Motorisierung, Fahrzeugklassen und Aufbauarten). 2021.
[Leh15]	J. Lehtinen. "Nonlinear Lateral Dynamic Behavior of a High Capacity Transport Vehicle". Masterarbeit. Aalto University Espo, 2015.
[LG04]	O. Lindgärde und M. Gäfvert. "A 9-DOF Tractor-Semitrailer Dynamic Handling Model for Advanced Chassis Control Studies". In: <i>Vehicle System Dynamics</i> 41.1 (2004), S. 51–82.
[LK09]	Y. H. Lee und A. Kade. "Trailer Articulation Angle Estimation". US Patent 2009/OOO5932 A1. 2009.
[LK18]	S. Lucia und B. Karg. "A deep learning-based approach to robust nonlinear model predictive control". In: <i>IFAC-PapersOnLine</i> 51.20 (2018), S. 511–516.
[LMD+02]	H. A. Lupker, F. Montanaro, D. Donadi, E. Gelosa und M. A. Vis. "Truck Tyre Wear Assessment and Prediction". In: <i>7th International Symposium on Heavv Vehicle Weights & Dimensions</i> (2002).
[LNZ ⁺ 18]	C. Liu, M. Neumann, B. Zoph, J. Shlens, W. Hua, LJ. Li, L. Fei-Fei, A. Yuille, J. Huang und K. Murphy. "Progressive Neural Architecture Search". In: <i>Proceedings of the European Conference on Computer Vision</i> (2018), S. 19–34.
[Luc17]	B. Luck. "Nichtlineare adaptive Störkraftkompensation und Regelung für Aktoren im Gaspfad moderner Verbrennungsmotoren". Dissertation. Gottfried Wilhelm Leibniz Universität Hannover, 2017.
[Lue64]	D. G. Luenberger. "Observing the State of a Linear System". In: <i>IEEE Transactions on Military Electronics</i> 8.2 (1964), S. 74–80.
[Lui10]	M. Luijten. "Lateral Dynamic Behaviour of Articulated Commercial Vehicles". Mas- terarbeit. Eindhoven University of Technology, 2010.
[Lun14]	J. Lunze. Regelungstechnik 2. Springer Berlin Heidelberg, 2014.
[Mac92]	D. J. C. MacKay. "A Practical Bayesian Framework for Backpropagation Networks". In: <i>Neural Computation</i> 4.3 (1992), S. 448–472.
[Mar63]	D. W. Marquardt. "An Algorithm for Least-Squares Estimation of Nonlinear Parameters". In: <i>Journal of the Society for Industrial and Applied Mathematics</i> 11 (1963), S. 431–441.

[MC05]	S. Mariani und A. Corigliano. "Impact induced composite delamination: state and parameter identification via joint and dual extended Kalman filters". In: <i>Computer Methods in Applied Mechanics and Engineering</i> (2005).
[MC11]	E. Mezura-Montesa und C. A. Coello Coello. "Constraint-Handling in Nature-Inspired Numerical Optimization: Past, Present and Future". In: <i>Swarm and Evolutionary Computation</i> (2011).
[MC15]	G. Morrison und D. Cebon. "Sideslip estimation for articulated heavy vehicles in low friction conditions". In: <i>Proceedings of the IEEE Intelligent Vehicles Symposium (IV)</i> (2015), S. 65–70.
[MPC+14]	G. F. Montufar, R. Pascanu, K. Cho und Y. Bengio. "On the Number of Linear Regions of Deep Neural Networks". In: arXiv preprint arXiv:1402.1869 (2014).
[MW14]	M. Mitschke und H. Wallentowitz. <i>Dynamik der Kraftfahrzeuge</i> . Springer Fachmedien Wiesbaden, 2014.
[MWP43]	McCulloch, Warren S. und W. H. Pitts. "A Logical Calculus of the Ideas Immanent in Nervous Activity". In: <i>The Bulletin of Mathematical Biophysics</i> 5 (1943), S. 115–133.
[Nel20]	O. Nelles. Nonlinear System Identification. Springer Berlin Heidelberg, 2020.
[NW90]	D. Nguyen und B. Widrow. "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights". In: <i>1990 IJCNN International Joint Conference on Neural Networks</i> . IEEE, 1990.
[OKA12]	S. T. Oreh, R. Kazemi und S. Azadi. "A new desired articulation angle for directional control of articulated vehicles". In: <i>Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-body Dynamics</i> 226.4 (2012), S. 298–314.
[ORR06]	B. J. Odelsen, M. Rajamani und J. B. Rawlings. "A New Autocovariance Least-Squares Method for Estimating Noise Covariances". In: <i>Automatica</i> 42.2 (2006), S. 303–308.
[Pac12]	H. B. Pacejka. Tire and Vehicle Dynamics. Elsevier, 2012.
[Pak01]	H. Paknia. "Identifizierung von Reifenkennfeldern aus Fahrmessungen auf der Strasse". Dissertation. RWTH Aachen, 2001.
[PB92]	H. B. Pacejka und E. Bakker. "The Magic Formula Tyre Model". Vehicle System

- Dynamics. In: 21.S1 (1992), S. 1–18.
- [Ped10] M. E. H. Pedersen. "Good Parameters for Particle Swarm Optimization". In: *Hvass Laboratories Technical Report no. HL1001* (2010).
- [PJW⁺14] S. Pliefke, P. Jarmola, T. Wierich, S. V. Byrne und Y. Lu. "Vehicle Vision System with Trailer Angle Detection". US Patent 2014/O16O276 A1. 2014.
- [PK05] K. L. Priddy und P. E. Keller. *Artificial Neural Networks: An Introduction*. SPIE press, 2005.

- [RBD⁺15] M. H. Riva, D. Beckmann, M. Dagen und T. Ortmaier. "Online parameter and process covariance estimation using adaptive EKF and SRCuKF approaches". In: *Proceedings* of the 2015 IEEE Conference on Control Applications (CCA). Piscataway, NJ: IEEE, 2015, S. 1203–1210.
- [RDO16] M. H. Riva, M. Dagen und T. Ortmaier. "Adaptive Unscented Kalman Filter for online state, parameter, and process covariance estimation". In: *Proceedings of the 2016 American Control Conference (ACC)*. IEEE, 2016, S. 4513–4519.
- [RET14] M. Y. Rupp, S. Elwart und R. A. Trombley. "Sensor System and Method for Monitoring Trailer Hitch Angle". US Patent 2014/0172232 A1. 2014.
- [RHW85] D. E. Rummelhart, G. E. Hinton und R. J. Williams. "Learning Internal Representations By Error Propagation". Technischer Bericht. University of California San Diego, 1985.
- [RR07] M. Rajamani und J. B. Rawlings. "Application of a New Data-based Covariance Estimation Technique to a Nonlinear Industrial Blending Drum". Technischer Bericht. University of Wisconsin-Madison, 2007.
- [SAE18] SAE J1939. Serial Control and Communications Heavy Duty Vehicle Network Top Level Document. 2018.
- [SAT19] K. B. Singh, M. A. Arat und S. Taheri. "Literature review and fundamental approaches for vehicle and tire state estimation". In: *Vehicle System Dynamics* 57.11 (2019), S. 1643–1665.
- [SBH⁺05] A. Schmeitz, I. Besselink, J. de Hoogh und H. Nijmeijer. "Extending the Magic Formula and SWIFT tyre models for inflation pressure changes". In: VDI Berichte 1912 (2005).
- [SGB⁺09] J. Svendenius, M. Gäfvert, F. Bruzelius und J. Hultén. "Experimental Validation of the Brush Tire Model5". In: *Tire Science and Technology* 37.2 (2009), S. 122–137.
- [Sha49] C. E. Shannon. "Communication in the Presence of Noise". In: *Proceedings of the IRE* 37.1 (1949), S. 10–21.
- [SHM87] J. Slotine, J. Hedrick und E. Misawa. "On Sliding Observers for Nonlinear Systems". In: *Journal of Dynamic Systems, Measurement, and Control* 109.3 (1987), S. 245–252.
- [Sin19] Singh, Alipour, Petry, Khadaoui. "Application of Machine Learning & Deep Learning Techniques in the Context of Use Cases Relevant for the Tire Industry". In: *VDI Wissensforum* (2019).
- [SJL14] P. Sundström, B. Jacobson und L. Laine. "Vectorized single-track model in Modelica for articulated vehicles with arbitrary number of units and axles". In: *Proceedings of the 10th International Modelica Conference*. Linköping University Electronic Press, 2014, S. 265–271.

[SRL+11]	E. N. Sanchez, L. J. Ricalde, R. Langari und D. Shahmirzadi. "Rollover Prediction and Control in Heavy Vehicles Via Recurrent High Order Neural Networks". In: <i>Intelligent Automation & Soft Computing</i> 17.1 (2011), S. 95–107.
[Sta21]	Statistisches Amt der Europäischen Union. Modal split of freight transport. 2021.
[TC09]	Z. Tianjun und Z. Changfu. "Modelling and Active Safe Control of Heavy Tractor Semi-Trailer". In: <i>Proceedings of the Second International Conference on Intelligent</i> <i>Computation Technology and Automation</i> (2009).
[TT08]	S. H. Tamaddoni und S. Taheri. "Yaw Stability Control of Tractor Semi-Trailers". In: <i>SAE Technical Paper Series</i> 2008-01-2595 (2008).
[Tun21]	N. T. Tung. "Experimental Analysis for Determination of Longitudinal Friction Coefficient Function in Braking Tractor Semi-trailer". In: <i>International Journal of</i> <i>Engineering</i> 34.7 (2021).
[TWH19]	S. Torabi, M. Wahde und P. Hartono. "Road Grade and Vehicle Mass Estimation for Heavy-duty Vehicles Using Feedforward Neural Networks". In: <i>Proceedings of the</i> <i>4th International Conference on Intelligent Transportation Engineering</i> (2019).
[van04]	R. van der Merwe. "Sigma-Point Kalman Filters for Probabilistic Inference in Dyna- mic State-Space Models". Dissertation. Oregon Health & Science University, 2004.
[VD97]	NG. Vågstedt und E. Dahlberg. "Determination of Lateral Axle Data of Heavy Vehicle Combinations". In: <i>SAE Transactions Section 2: Journal of Commercial Vehicles</i> 106.2 (1997), S. 440–447.
[WB95]	G. Welch und G. Bishop. "An Introduction to the Kalman Filter". Artikel. University of North Carolina at Chapel Hill, 1995.
[WHL+15]	H. Winner, S. Hakuli, F. Lotz und C. Singer. <i>Handbuch Fahrerassistenzsysteme</i> . Springer Fachmedien Wiesbaden, 2015.
[Wie20]	M. Wielitzka. "Zustands- und Reibwertschätzung in der Fahrzeugdynamik". Disserta- tion. Leibniz Universität Hannover, 2020.
[Wil51]	D. Williams. "The Mathematical Theory of the Snaking of Two-wheeled Trailers, with Practical Rules and Devices for Preventing Snaking". In: <i>Proceedings of the Institution of Mechanical Engineers: Automobile Division</i> 5.1 (1951), S. 175–190.
[Wil98]	HP. Willumeit. <i>Modelle und Modellierungsverfahren in der Fahrzeugdynamik</i> . Springer Fachmedien Wiesbaden, 1998.
[Woe16]	C. Woernle. Mehrkörpersysteme. Springer Berlin Heidelberg, 2016.
[Wol14]	S. M. Wolfe. "Heavy Truck Modeling and Estimation For Vehicle-To-Vehicle Collisi- on Avoidance Systems". Dissertation. The Ohio State University, 2014.

- [Wor21] World Trade Organization. World Trade Organization Statistical Review 2021. 2021. URL: https://www.wto.org/english/res_e/statis_e/wts2021_ e/wts21_toc_e.htm.
- [XTP⁺17] L. Xu, E. Tseng, T. Pilutti und S. Schondorf. "Yaw Rate Based Trailer Hitch Angle Estimation for Trailer Backup Assist". In: *SAE Technical Paper Series*. 2017.
- [ZKO⁺21] J. Zumsande, K.-P. Kortmann, T. Ortmaier und M. Wielitzka. "Estimation of Stochastic Time Lags between Data Sources in Distributed Production Facilities Based on Cross-Correlated Signals". In: 22nd International Conference on Industrial Technology (ICIT). IEEE, 2021, S. 881–888.

Lebenslauf

	zu meiner Person
Name, Vorname	Ziaukas, Zygimantas
Familienstand	ledig
Staatsangehörigkeit	deutsch

beruflicher Werdegangseit Okt/22Technischer Projektleiter bei ZF Friedrichshafen AGJuni/21 - Sep/22Forschungsgruppenleiter Identifikation & Regelung am Institut für
Mechatronische Systeme, Leibniz Universität Hannover (LUH)Feb/17 - Sep/22Wissensch. Mitarbeiter am Institut für Mechatronische Systeme, LUH

Studium

Apr/15 - Sep/16	Masterstudium des Wirtschaftsingenieurwesens an der LUH
	Techn. Vertiefung: Mechatronik,
	Ökon. Vertiefung: Geld und Internationale Finanzwirtschaft
	Abschluss am 21. September 2016, Gesamtnote (1,3)
Okt/11 - Mär/15	Bachelorstudium des Wirtschaftsingenieurwesens an der LUH
	Techn. Vertiefung: Mechatronik

studienbegleitende Tätigkeiten und Praktika

- Okt/12 Jan/17 Hilfswissenschaftler (mit Unterbrechungen) am Institut für Mechatronische Systeme, LUH
- Sep/14 Dez/14 Praktikum bei der Volkswagen AG (Abt. Leistungselektronik), Isenbüttel

Schulbildung

Aug/02 - Jul/11	CJD Gymnasium Versmold,
	Abschluss am 04. Juli 2011: Abitur (1,9)
Okt/08 - Apr/09	Schüleraustausch Merrimac State High School, Mermaid Waters,
	Australien
Apr/98 - Jun/02	Grundschule Bad Rothenfelde