

Analyse des Fahrverhaltens eines autonomen Rennfahrzeugs anhand eines Giermomentdiagramms und echtzeitfähige Adaption an reale Fahrzeugsensordaten

Analysis of the driving behavior of an autonomous racing car using a yaw moment diagram and real-time adaptation to vehicle sensor data

Wissenschaftliche Arbeit zur Erlangung des Grades

Master of Science (M.Sc.)

an der Fakultät 03 für Maschinenbau, Fahrzeugtechnik, Flugzeugtechnik der Hochschule München

Betreut von Prof. Dr. Peter Pfeffer, Hochschule München
Leonhard Hermansdorfer, M.Sc., Technische Universität München

Eingereicht von Frederik Werner, B.Eng.
Radolfzellerstraße 38
81243 München

Eingereicht am 13. Juni 2021

Aufgabenstellung

Analyse des Fahrverhaltens eines autonomen Rennfahrzeugs anhand eines Giermomentendiagramms und echtzeitfähige Adaption an reale Fahrzeugsensordaten

Im Rahmen der Indy Autonomous Challenge (IAC) entwickelt der Lehrstuhl für Fahrzeugtechnik der Technischen Universität München Software für ein autonomes Rennfahrzeug, welches an einem internationalen Rennwettbewerb teilnehmen wird. Im Fokus steht dabei das Antreten gegen die Software anderer Teams. Diese Abschlussarbeit soll zur Entwicklung einer leistungsfähigen Software beitragen.

Im Motorsport bewegt der Rennfahrer das Fahrzeug im Optimalfall kontinuierlich im fahrdynamischen Grenzbereich. Der Rennfahrer ist in der Lage, das Fahrzeug in solchen Situationen mit einer entsprechenden Reaktion zu stabilisieren und auf der Rennlinie zu halten. Giermomentendiagramme (GMD) nach der „Milliken Moment Method“ werden im Motorsport verwendet, um das Fahrverhalten auf Basis eines Fahrdynamikmodells zu analysieren und daraus Setup-Änderungen abzuleiten. Generell ergibt sich dabei die Problematik von Modellabweichungen zum realen Fahrzeugverhalten, das durch den Fahrzeugzustand und die Streckenbedingungen beeinflusst wird.

Im Rahmen der Masterarbeit soll das Fahrverhalten eines autonomen Rennfahrzeugs anhand des GMDs nach Milliken untersucht werden. Unter Verwendung eines erprobten Regelungs-Algorithmus soll untersucht werden, wie sich dieser auf das Fahrverhalten am Limit und besonders auf die Stabilität, Kontrolle und das Eigenlenkverhalten auswirkt. Im zweiten Schritt soll ein Algorithmus entworfen und implementiert werden, der es ermöglicht, das modellbasierte GMD in Echtzeit auf dem Rennfahrzeug an die Sensordaten anzupassen. Dadurch soll die Fahrzeugperformance in Echtzeit an den Fahrzeugzustand und die Umgebungsbedingungen angepasst werden. Die Umsetzung der Masterarbeit soll vorzugsweise in Python erfolgen.

Ziel dieser Masterarbeit ist die Entwicklung und Implementierung eines Algorithmus zur Analyse des Fahrverhaltens und zur Online Adaption des GMD mit dem Ziel der Steigerung der Fahrzeugperformance. Folgende Punkte sind zu bearbeiten:

- Stand der Technik: Entwicklung und Varianten der „Milliken Moment“ Methode
- Einarbeitung in die vorhandene Fahrdynamiksimulation und Regelungs-Software
- Erstellung des GMD und erste Parameteranalysen
- Entwicklung und Ausarbeitung eines Konzepts zur echtzeitfähigen Anpassung des GMDs auf Fahrzeugsensordaten; Implementierung des Ansatzes in Python
- Test und Validierung des Algorithmus mittels aufgezeichneter Realfahrzeugdaten und am Hardware-in-the-Loop (HiL)-Simulator

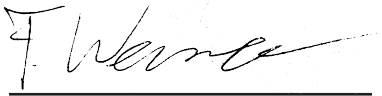
Die Ausarbeitung soll die einzelnen Arbeitsschritte in übersichtlicher Form dokumentieren. Der Kandidat verpflichtet sich, die Studienarbeit selbständig durchzuführen und die von ihm verwendeten wissenschaftlichen Hilfsmittel anzugeben.

Die eingereichte Arbeit verbleibt als Prüfungsunterlage im Eigentum des Lehrstuhls und darf Dritten nur unter Zustimmung des Lehrstuhlinhabers zugänglich gemacht werden.

Erklärung

Ich versichere hiermit, dass ich die von mir eingereichte Abschlussarbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe.

München, den 13. Juni 2021

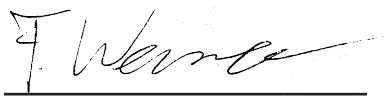


Frederik Werner, B.Eng.

Declaration of Consent, Open Source

Hereby I, Werner, Frederik, born on March 26, 1994, make the software I developed during my Master Thesis available to the Institute of Automotive Technology of the Technical University of Munich under the terms of the license below.

Munich, June 13, 2021



Frederik Werner, B.Eng.

Copyright 2021 Werner, Frederik

Permission is hereby granted, free of charge, to any person obtaining a copy of this software and associated documentation files (the "Software"), to deal in the Software without restriction, including without limitation the rights to use, copy, modify, merge, publish, distribute, sublicense, and/or sell copies of the Software, and to permit persons to whom the Software is furnished to do so.

THE SOFTWARE IS PROVIDED "AS IS", WITHOUT WARRANTY OF ANY KIND, EXPRESS OR IMPLIED, INCLUDING BUT NOT LIMITED TO THE WARRANTIES OF MERCHANTABILITY, FITNESS FOR A PARTICULAR PURPOSE AND NONINFRINGEMENT. IN NO EVENT SHALL THE AUTHORS OR COPYRIGHT HOLDERS BE LIABLE FOR ANY CLAIM, DAMAGES OR OTHER LIABILITY, WHETHER IN AN ACTION OF CONTRACT, TORT OR OTHERWISE, ARISING FROM, OUT OF OR IN CONNECTION WITH THE SOFTWARE OR THE USE OR OTHER DEALINGS IN THE SOFTWARE.

Inhaltsverzeichnis

Abkürzungsverzeichnis	III
Formelzeichen	V
1 Einleitung	1
2 Stand der Technik	3
2.1 Fahrdynamikmodellierung	3
2.1.1 Einspurmodell.....	3
2.1.2 Zweispurmodell.....	5
2.1.3 Reifenmodell Pacejka Magic Formula	7
2.2 Giermomentdiagramme	10
2.2.1 Milliken Moment Method.....	10
2.2.2 Bewertung des Fahrzeugverhaltens	12
2.2.3 Stabilität, Kontrolle und Dämpfung	15
2.3 Ermittlung des Fahrbahn-Reifen-Reibwerts	17
2.3.1 Mechanismen der Fahrbahn-Reifen-Reibung	17
2.3.2 Veränderung des Reifenverhaltens bei wechselnden Fahrbahn-Reifen-Zuständen	18
2.3.3 Methoden zur Reibwertschätzung	21
2.3.4 Reibwertschätzung im Anwendungsfall autonomer Rennfahrzeuge	23
2.4 Machine Learning Verfahren zur Regression	24
2.4.1 Vorstellung ausgewählter Verfahren	25
2.4.2 Fehler-Metriken	30
3 Methoden A: Erstellung von Giermomentdiagrammen	33
3.1 Zielsetzung	33
3.2 Aufbau der Giermomentdiagramm-Anwendung	34
3.2.1 Modelldesign.....	34
3.2.2 Simulationsablauf.....	39
3.2.3 Postprocessing	40
4 Ergebnisse A: Analyse der erstellten Giermomentdiagramme	45
4.1 Konvergenzverhalten	45

4.2 Einfluss der Geschwindigkeit und Längsbeschleunigung	46
4.3 Interpretation der Stabilität, Kontrolle und Dämpfung	48
4.4 Parameterstudien	50
4.5 Korrelation der Giermomentendiagramme mit Messdaten	54
4.5.1 Korrelation der Querb beschleunigung.....	55
4.5.2 Korrelation des Giermoments	56
4.5.3 Plausibilisierung von Stabilität und Kontrolle	57
5 Methoden B: Echtzeitfähige Adaption von Messdaten	59
5.1 Schätzung des Querb beschleunigungs limits des Gesamtfahrzeugs.....	59
5.1.1 Hypothese	59
5.1.2 Architektur des Algorithmus	60
5.1.3 Regressionsverfahren	62
5.1.4 Skalierung des Reibwertes	65
5.1.5 Erstellung von Reibwertkarten	67
5.2 Trainingsprozess des neuronalen Netz.....	68
6 Ergebnisse B: Echtzeitfähige Adaption von Messdaten	71
6.1 Training des neuronalen Netzes.....	71
6.2 Schätzung der Querb beschleunigungs limits	74
6.2.1 Anwendung des Algorithmus.....	74
6.2.2 Closed-Loop Anwendung des Algorithmus	78
6.2.3 Untersuchung zur Streuung der Schätzung.....	82
7 Diskussion	85
7.1 Erstellung und Analyse von Giermomentendiagrammen	85
7.2 Echtzeitfähige Schätzung der Querb beschleunigungs limits	87
8 Zusammenfassung und Ausblick	91
Abbildungsverzeichnis.....	i
Tabellenverzeichnis	v
Literaturverzeichnis	vii

Abkürzungsverzeichnis

ABS	Antiblockiersystem (engl. Anti-lock Braking System)
ADAS	Advanced Driver Assistance Systems
AEB	Autonomous Emergency Braking
AI	Artificial Intelligence
ANN	Artificial Neuronal Network
CNN	Convolutional Neuronal Network
DNN	Deep Neuronal Network
ESM	Einspurmodell
ESP	Elektronisches Stabilitätsprogramm
FEM	Finite Elemente Methode
GMD	Giermomentdiagramm
HiL	Hardware-in-the-Loop
IAC	Indy Autonomous Challenge
IMS	Indianapolis Motor Speedway
KNN	k-Nearest Neighbor
KPI	Key Performance Indicator
MAE	Mean Absolute Error
ML	Machine Learning
MLP	Multi Layer Perceptron
MMM	Milliken Moment Method
MSE	Mean Squared Error
RMSE	Root Mean Squared Error
RNN	Recurrent Neuronal Network
SiL	Software-in-the-Loop
TTC	Time-To-Collision
TV	Torque Vectoring
ZSM	Zweispurmodell

Formelzeichen

Lateinische Formelzeichen

Formelzeichen	Einheit	Beschreibung
A	m^2	Projektionsfläche
a	m/s^2	Beschleunigungsvektor
$a_{x,y,z}$	m/s^2	Translatorische Beschleunigungskomponente
$a_{y,lim}$	m/s^2	Querbeschleunigungslimit
BB		Bremsbalance
b		Bias
C_α	N/rad	Schräglaufsteifigkeit des Reifens
$C_{\alpha,f}$	N/rad	Schräglaufsteifigkeit der Vorderachse
$C_{\alpha,r}$	N/rad	Schräglaufsteifigkeit der Hinterachse
C_{M_z}	$Ns^2 kg^{-1} m^{-1}$	Giermomentskoeffizient
$CoG_{x,y,z}$	m	Schwerpunktsvektor
c_a		Abtriebsbeiwert
$c_{a,f}$		Abtriebsbeiwert Vorderachse
$c_{a,r}$		Abtriebsbeiwert Hinterachse
c_w		Widerstandsbeiwert
D_Ψ	$kg m^2 s^{-1}$	Gierdämpfung
e_β	rad	Regelabweichung Schwimmwinkel
e_v	m/s	Regelabweichung Geschwindigkeit
F	N	Kraftvektor
F_A	N	Abtriebskraft
F_N	N	Normalkraft
$F_{x,y,z}$	N	Kraftkomponente
f_k		Faktor Konfidenzniveau
f_s		Faktor Skalierung Reifenmodell

f_{TV}		Faktor Torque Vectoring
g	m/s^2	Erdbeschleunigung
$I_{x,y,z}$	$kg\ m^2$	Rotationsträgheit
K_P		Proportionaler Verstärkungsfaktor
K_I		Integraler Verstärkungsfaktor
K_D		Differentieller Verstärkungsfaktor
l	m	Radstand
l_f	m	Abstand Vorderachse zu Schwerpunkt
l_r	m	Abstand Hinterachse zu Schwerpunkt
M_r	Nm	Antriebsmoment Rad
$M_{x,y,z}$	Nm	Momentkomponente
M_z	Nm	Giermoment
$M_{z,TV}$	Nm	Giermoment durch Torque Vectoring
m	kg	Fahrzeugmasse
p_B	Pa	Bremsdruck
p_f	Pa	Bremsdruck Vorderachse
p_r	Pa	Bremsdruck Hinterachse
r	m	Kreisradius
S_α		Querschlupf
S_h		Horizontaler Verschiebungsfaktor Pacejka Magic Formula
S_v		Vertikaler Verschiebungsfaktor Pacejka Magic Formula
TW	m	Spurweite
$v_{x,y,z}$	m/s	Geschwindigkeitskomponente
W		Gewichtungsvektor
WB	m	Radstand
X		Eingangsvektor
X, Y, Z	m	Position

Griechische Formelzeichen

Formelzeichen	Einheit	Beschreibung
α	rad	Schräglaufwinkel Reifen
α_f	rad	Schräglaufwinkel Vorderachse
α_r	rad	Schräglaufwinkel Hinterachse
β	rad	Schwimmwinkel
δ	rad	Radlenkwinkel
γ	rad	Fahrbahnneigungswinkel
κ	m^{-1}	Krümmung
λ		Reifenlängsschlupf
μ_x		longitudinaler Reibwert
μ_y		lateraler Reibwert
μ_{max}		maximaler Reibwert
Φ	rad	Rollwinkel
Ψ	rad	Gierwinkel
$\dot{\psi}$	rad/s	Gierrate
$\ddot{\psi}$	rad/s ²	Gierbeschleunigung
ρ	Pa	Luftdruck
σ		Standardabweichung
Θ	rad	Nickwinkel
ω	rad/s	Raddrehzahl
ω_0	rad/s	Raddrehzahl des frei rollenden Rades

1 Einleitung

Das autonome Fahren ist eine der vier Megatrends in der aktuellen Entwicklung der Automobilindustrie [1]. Fahrzeuge mit Autonomiefunktionen zwischen Level 3-5, gemäß der Klassifizierung in SAE J3016 [2] können viele Vorteile für die Gesellschaft und das Individuum bieten. Es wird erwartet, dass ein verbreiteter Einsatz von autonomen Fahrzeugen unter anderem zu steigender Sicherheit, sinkenden Reisezeiten und höherer Energieeffizienz führt [3, 4]. Die Automobilindustrie, die früher die Markteinführung vollautonomer Fahrzeuge bis 2020 prognostizierte, ist von diesem Optimismus abgerückt, weil sich die Entwicklung der benötigten Sensoren und Softwarealgorithmen komplexer als erwartet herausgestellt hat [5]. Ein Schwerpunkt der Entwicklung von autonomen Fahrzeugen liegt auf der Verhinderung oder Reduzierung von Unfällen und Unfallauswirkungen [6–8]. Unfallvermeidungsszenarien beinhalten zwangsläufig Fahrsituationen im Grenzbereich des Fahrzeugs. Der Motorsport bietet ein hervorragendes Umfeld, um das sichere Führen eines autonomen Fahrzeugs im Grenzbereich zu testen und Erfahrungen zu sammeln, von denen die Serienentwicklung profitieren kann.



Abbildung 1.1: Das modifizierte Dallara IL-15 Chassis für den autonomen Renneinsatz auf dem Indianapolis Superspeedway im Rahmen der Indy Autonomous Challenge (IAC) [9]

Im Rahmen der Roborace Rennserie für autonome Fahrzeuge und der IAC entwickelt das Autonomous Racing Team der Technischen Universität München Software für das autonome Fahren bei hohen Geschwindigkeiten und im Grenzbereich des Fahrzeugs. In der Vergangenheit sammelte das Team Erfahrungen durch die Teilnahme an der Roborace-Rennserie mit einem elektrischen Rennfahrzeug namens "Devbot". Das heckangetriebene Fahrzeug konnte mit einem menschlichen Fahrer und im autonomen Modus betrieben werden. In der kommenden Herausforderung IAC am 23.10.2021 wird im Bereich des autonomen Fahrens Neuland betreten. Ziel ist es, in mit zusätzlichen Sensoren ausgestatteten Dallara IL-15 Fahrzeugen, wie in Abbildung 1.1 gezeigt, ein Rennen über 20 Runden auf dem Indianapolis Motor Speedway (IMS)

zu fahren [10]. Die Fahrzeuge werden vollautonom und mit mehreren gegnerischen Fahrzeugen gleichzeitig auf der Strecke sein. Die möglichen Spitzengeschwindigkeiten von 320 km/h und Querbeschleunigungen über $3g$, führen zusammen mit den Mehrfahrzeugszenarien zu einer neuartigen Herausforderung für autonome Rennfahrzeuge.

Ein erfolgreiches Abschneiden erfordert einen geplanten und ungeplanten Betrieb im Grenzbe- reich des Fahrzeugs, um die Quer- und Längsbeschleunigung zu maximieren und die Rundenzeit zu minimieren. Dies erfordert eine gute Kenntnis und Ausnutzung der fahrdynamischen Gren- zen. Da sich die Grenzen während der Fahrt durch eine Vielzahl von Einflussfaktoren ständig ändern können, ist eine permanente Überwachung notwendig. Aufgrund der Rennszenarios mit mehreren Fahrzeugen kann es zu unvorhergesehen Situationen mit langsamen oder stehenden Fahrzeugen auf der aktuell geplanten Trajektorie kommen. Die verbaute Sensorik besteht aus Lidar, Radar und Kamera Systemen. Aufgrund der theoretischen Sichtweiten der Systeme von $180 - 250\text{ m}$ [11, 12] geht das Team davon aus, dass ab 200 m Vorausschaulistanz Objekte erkannt werden können und ab 100 m die Objekte mit einer hohen Detektionsgüte in Bezug auf die relative Position und den Geschwindigkeitsvektor vorliegen. Daraus ergibt sich bei Höchstge- schwindigkeit eine Vorausschauzeit von $< 2,3\text{ s}$ für die erste Detektion und $< 1,2\text{ s}$ für eine hohe Detektionsgüte. Diese geringe Zeitspanne kann zur Planung von Ausweichtrajektorien führen, für die das maximale Querbeschleunigungspotential des Fahrzeugs verwendet werden muss. Die Sicherstellung der Fahrzeugstabilität ist ebenso erforderlich.

Mit der Milliken Moment Method (MMM) können der Manöverraum und Key Performance Indicator (KPI) zur Bewertung der Kontrolle und Stabilität eines Fahrzeugs berechnet werden. Die Berechnung erfolgt für unterschiedliche Geschwindigkeits- und Beschleunigungs-/Brems- Situationen auf Basis einer detaillierten Gesamtfahrzeugsimulation [13]. Basierend auf Methoden in der Flugzeugentwicklung beschäftigt sich die MMM mit der Betrachtung von Kräften und Momenten auf das Gesamtfahrzeug im Gleichgewichtszustand und in Situationen in denen kein Gleichgewichtszustand herrscht. Dargestellt werden die Ergebnisse in Giermomentdiagrammen.

Das Ziel für den ersten Teil dieser Arbeit ist die Entwicklung einer Anwendung zur Erstellung von Giermomentdiagrammen, die die bereits existierenden Fahrdynamikmodelle des Teams integriert. Die Arbeit von *Milliken* und *Milliken* [14, S.293-340] beschreibt dazu die Grundlagen und wird in Unterkapitel 2.2 vorgestellt. Die Arbeit von *Kang et al.* [15] schlägt eine Methodik zur Integration beliebiger Fahrdynamikmodelle vor, auf der diese Arbeit aufbaut. Die Methodik wird in Kapitel 3 aufgezeigt. Im nächsten Schritt wird in Abschnitt 3.2.3 ein Postprocessing entwickelt, um aus den Diagrammen automatisiert KPIs zu errechnen. Mithilfe der KPIs kann eine Anwendung für Parameter- und Modellstudien entwickelt werden.

Im zweiten Teil dieser Arbeit wird in Kapitel 5 eine Methodik vorgestellt, wie durch die Daten aus den Giermomentdiagrammen die lokalen Querbeschleunigungslimits in Echtzeit auf dem Rennfahrzeug ermittelt werden können. Dieser Ansatz unterscheidet sich von gängigen mo- dellbasierten Reibwertschätzungsalgorithmen [16, 17] über die in Abschnitt 2.3.3 ein Überblick gegeben wird. Grundsätzlich orientiert sich der Ansatz an dem Vorschlag von *Milliken et al.*, Reifendaten mithilfe von Giermomentdiagrammen an die aktuelle Fahrsituation anzupassen [18]. Um den Rechenaufwand zu senken, wird ein neuronales Netz mit den Simulationsergebnissen trainiert, um den Algorithmus in Echtzeit auf dem Fahrzeug ausführen zu können. Die Methodik des Trainings wird in Unterkapitel 5.2 und das Trainingsergebnis in Unterkapitel 6.1 vorgestellt.

2 Stand der Technik

Die Arbeit führt Wissen und Methoden aus den Bereichen Fahrdynamik, Modellierung, Regelungstechnik, Reibwertschätzung, Machine Learning und Echtzeitprogrammierung zusammen und ist deshalb im Stand der Technik in vier Hauptbereiche untergliedert. In Unterkapitel 2.1 werden die Grundlagen zur Fahrdynamik- und Reifenmodellierung beschrieben. In Unterkapitel 2.2 werden die Grundlagen der Milliken Moment Method zur Erstellung von Giermomentdiagrammen aufgezeigt. Unterkapitel 2.3 schließt an mit Hintergründen zur Fahrbahn-Reifenverbindung und Reibwertschätzung. In Unterkapitel 2.4 werden die Grundlagen von Machine Learning und Neuronalen Netzen für Regressionsanwendungen dargestellt. Zum Bereich der Regelungstechnik gibt es kein dediziertes Grundlagenkapitel, die verwendeten Methoden werden in Abschnitt 3.2.1 und Unterkapitel 4.1 beschrieben

2.1 Fahrdynamikmodellierung

Die Fahrdynamikmodellierung beschäftigt sich mit der Abbildung des Systemverhaltens eines Fahrzeugs durch geeignete Differentialgleichungen und Kennfelder. Ein Modell ist eine vereinfachte mathematische Abbildung der Realität und je nach Grad der Vereinfachung haben sich unterschiedliche Ansätze etabliert. In Abschnitt 2.1.1 wird das Einspurmodell vorgestellt. Abschnitt 2.1.2 schließt mit einer Vorstellung des umfangreicheren Zweispurmodells an. Die Reifenmodellierung ist aufgrund der zugrundeliegenden Komplexität und Nichtlinearität der Reifeneigenschaften ein Thema von hohem Interesse in der Fahrdynamikmodellierung. In Abschnitt 2.1.3 wird auf das Magic Formula Modell von *Pacejka* [19] eingegangen. Die mathematischen Beziehungen des Einspurmodells und des Zweispurmodells sind in der Literatur umfangreich beschrieben, sodass in dieser Sektion nur auf die Grundlagen eingegangen wird. Weiterführende Informationen sind in [20–25] zu finden.

2.1.1 Einspurmodell

Das Einspurmodell existiert seit 1940 und wurde von *Riekert et. al.* entwickelt [20]. In seiner linearen Form wird von einigen Vereinfachungen ausgegangen. Neben der Reduktion auf eine Spur wird das Reifenverhalten als linear angenommen und der Angriffspunkt aller Kräfte auf die Fahrbahnebene gelegt. Aufgrund dieser Vereinfachungen entfallen alle Effekte durch Wanken oder Nicken. Die Linearisierung des Reifens reduziert die Anwendbarkeit des Modells auf den im Bereich geringer Beschleunigungen $< 4 \text{ m/s}^2$ [24, S. 77]. Die Komplexität, der Rechenzeitbedarf und der Parametrierungsaufwand sind gering. Daher eignet sich das Einspurmodell für grundlegende Systementwürfe von Komponenten oder den Echtzeitbetrieb auf dem Fahrzeug.

Das im weiteren Verlauf der Arbeit verwendete Einspurmodell (ESM) des TUM Autonomous Racing Teams wurde um ein nichtlineares Reifenmodell und ein einfaches Aerodynamikmodell erweitert [26]. Das bestehende Modell unterliegt folgenden Modellvereinfachungen:

- Die Räder werden achsweise zusammengefasst. Der gedachte Radaufstandspunkt liegt auf der Fahrzeuglängsachse [22, S.613].
- Der Schwerpunkt des Fahrzeugs wird auf Fahrbahnhöhe angenommen. Alle Reifen- und Reaktionskräfte des Fahrzeugs liegen dadurch in der Fahrbahnebene. Es entstehen demnach keine Roll- und Nickbewegungen des Fahrzeugs [22, S.613].
- Die aerodynamischen Kräfte in vertikaler Richtung werden über einen Abtriebsbeiwert für die Vorderachse $c_{a,f}$ und für die Hinterachse $c_{a,r}$ achsweise zusammengefasst. In Richtung der Fahrzeuglängsachse werden die aerodynamischen Kräfte über einen Widerstandsbeiwert c_w modelliert, der im Schwerpunkt angreift.
- Effekte der Radaufhängungskinematik, über die Lenkübersetzung hinaus, werden vernachlässigt [21, S.243].




Abbildung 2.1: Einspurmodell in der Kurvenfahrt um den Momentanpol. Die relevanten Zustandsgrößen zur Beschreibung der Fahrsituation sind in der Abbildung eingezeichnet. [26, S.7]

Die Bewegungsgleichungen und benötigten Modellparameter des nichtlinearen Einspurmodells können aus den genannten Quellen in Unterkapitel 2.1 entnommen werden. Die Fahrdynamikmodellierung basiert auf den bestehenden Modellen des TUM Autonomous Racing Teams und ist nicht Schwerpunkt dieser Arbeit. Die verwendete Notation der Zustandsgrößen wird in

Abbildung 2.1 eingeführt. Die Auflistung der wichtigsten Eingangs- und Ausgangsvariablen wird in Tabelle 2.1 gegeben.

Tabelle 2.1: Die wichtigsten Eingangs- und Ausgangsgrößen des verwendeten Einspurmodells

(a) Eingangsgrößen		(b) Ausgangsgrößen	
Variablenname	Symbol	Variablenname	Symbol
Antriebsmoment	M_r	Position	X, Y, Z
Bremsdruck	p_f, p_r	Gierwinkel	Ψ
Lenkwinkel	δ_f	Gierrate	$\dot{\Psi}$
Externe Kräfte	$F_{x,y,z}$	Schräglaufwinkel	$\alpha_{f,r}$
Externe Momente	$M_{x,y,z}$	Schwimmwinkel	β
		Geschwindigkeit	$v_{x,y}$
		Beschleunigung	$a_{x,y}$
		Raddrehzahlen	$\omega_{f,r}$

Durch die verwendeten Modellvereinfachungen bestehen bei der Verwendung des nichtlinearen Einspurmodells Einschränkungen. Dem Modell ist es nicht möglich Effekte dynamischer Radlastverlagerungen und des degressiven Reifenreibwerts abzubilden. Dadurch eignet es sich nur bedingt für Untersuchungen im Grenzbereich und Situationen unter Längsbeschleunigung.

2.1.2 Zweispurmodell




Abbildung 2.2: Zweispurmodell in der Kurvenfahrt um den Momentanpol. Die relevanten Zustandsgrößen zur Beschreibung der Fahrsituation sind in der Abbildung eingezeichnet. [26, S.12]

Das Zweispurmodell (ZSM) ist eine Weiterentwicklung des ESM und ermöglicht eine detailliertere Modellierung der Fahrzeugdynamik. Im Gegensatz zum ESM ist das ZSM in der Lage, Hub-, Roll- und Nickbewegungen und die damit verbundenen Radlastschwankungen darzustellen. Dadurch kann das nichtlineare, degressive Reifenverhalten im Grenzbereich berücksichtigt werden. Für Simulationen bei hohen Quer- und Längsbeschleunigungen ist das von besonderem Interesse. Weitere allgemeine Vorteile des Zweispurmodells liegen in der Abbildung von folgenden Effekten:

- **Radaufhängungskinematik:** Die Einfederung der Reifen führt durch die Aufhängungsgeometrie zur Veränderung der Radwinkel, wie Sturz, Spur und Nachlauf.
- **Elastokinematik:** Neben den geometrischen Effekten der Radaufhängungskinematik können elastokinematische Effekte, die aus der Verformung der Aufhängungskomponenten unter Krafteinwirkung resultieren, modelliert werden.
- **Schwingungsverhalten:** Durch die Modellierung der Feder-Dämpfer-Elemente kann das Schwingungsverhalten der Karosserie untersucht werden. Dazu gehören sowohl die Einzelrad-Feder-Dämpfer-Elemente, achsverbindende Federn (Stabilisatoren), sowie die Feder-Dämpfer-Eigenschaften der Reifen.
- **Antriebsmomentenverteilung:** Durch eine unterschiedliche Verteilung der Antriebsmomente kann ein Giermoment um die Hochachse des Fahrzeugs M_z erzeugt werden.

Die Implementierung des ZSM durch das TUM Autonomous Racing Team basiert auf dem *Vehicle Dynamics Blockset* von *MATLAB Simulink* und wurde von *Schindler* [26] entwickelt. Abweichend von der vorangegangenen Beschreibung wird auf eine Abbildung der (elasto-)kinematischen Effekte verzichtet [26, S.13]. Änderungen in der Radlast führen dadurch nicht zu einer Veränderung der Radwinkel Sturz, Spur oder Nachlauf. Die Aerodynamik wird vergleichbar mit dem ESM durch einen Abtriebsbeiwert c_a , einem Widerstandsbeiwert c_w und einer festen Verteilung der aerodynamischen Kräfte auf Vorder- und Hinterachse dargestellt [26, S.18]. Die Zustandsgrößen werden in Abbildung 2.2 eingeführt. Die Modellherleitung basiert auf zwei vereinfachenden Annahmen [21, S.253ff]. Zum einen entspricht die Positionierung der vier Räder der geometrischen Positionierung im realen Fahrzeug und wird für jedes Rad mit einem Radaufstandspunkt modelliert. Zum anderen wird die Fahrzeugmasse als Punktmasse im aufbaufesten Koordinatensystem mit x,y,z Koordinaten modelliert. Die Bewegungsgleichungen und benötigten Modellparameter des ZSM können aus den genannten Quellen in Unterkapitel 2.1 entnommen werden. Aufgrund der Erweiterungen des ZSM gibt es Eingangs- und Ausgangsvariablen, die im Vergleich zum ESM hinzukommen. Tabelle 2.2 ist korrespondierend zu Tabelle 2.1 des Einspurmodells.

Kritisch ist anzumerken, dass die vorhandene Implementierung des ZSM einige Vereinfachungen vornimmt. Es wird angenommen, dass diese Vereinfachungen einen messbaren Einfluss auf das Fahrzeugverhalten haben. Diese Vermutung wird in Unterkapitel 4.4 untersucht. Die relevantesten Vereinfachungen der Implementierung sind:

- **Kinematische Einflüsse:** Wie bereits beschrieben, werden die kinematischen Effekte, die auf der Geometrie und den Elastizitäten der Radaufhängung basieren, nicht modelliert. Es sei erwähnt, dass die verwendeten Blöcke des *Simulink Vehicle Dynamic Blockset* prinzipiell die geometrischen Effekte der Radaufhängungskinematik über Kennlinien annähern können. Aufgrund fehlender Parametrierungsdaten seitens Roborace und IAC ist die Modellierung der Kinematik bisher nicht umgesetzt.

Tabelle 2.2: Die wichtigsten Eingangs- und Ausgangsgrößen des verwendeten Zweispurmodells

(a) Eingangsgrößen		(b) Ausgangsgrößen	
Variablenname	Symbol	Variablenname	Symbol
Antriebsmoment	$M_{FL,FR,RL,RR}$	Position	X, Y, Z
Bremsdruck	p_f, p_r	Gierwinkel	Ψ
Lenkwinkel	$\delta_{FL,FR}$	Nickwinkel	Θ
Externe Kräfte	$F_{x,y,z}$	Rollwinkel	Φ
Externe Momente	$M_{x,y,z}$	Gierrate	$\dot{\psi}$
		Schräglaufwinkel	$\alpha_{FL,FR,RL,RR}$
		Schwimmwinkel	β
		Geschwindigkeit	$v_{x,y,z}$
		Beschleunigung	$a_{x,y,z}$
		Raddrehzahlen	$\omega_{FL,FR,RL,RR}$

- **Zustandsabhängige Aerodynamik:** In der gewählten Implementierung werden die aerodynamischen Kräfte nicht durch Änderungen der Bodenfreiheit von Vorder- und Hinterachse, Schwimmwinkel, Lenkwinkel und Wankwinkel beeinflusst. Für Rennfahrzeuge, bei denen die Aerodynamik in Abhängigkeit von der Geschwindigkeit einen großen zweistelligen prozentualen Anteil an der Summe der Radaufstandskräfte hat, ist dies eine Vereinfachung, die das Fahrzeugverhalten beeinflussen kann. [27, S.238ff]
- **Freie Radmomentenverteilung:** Die Eingänge des Modells erlauben eine individuelle Momentenvorgabe. Es ist daher die Aufgabe der vorgelagerten Blöcke, die Momentenverteilung vorzugeben. Das zusätzliche Giermoment, das durch eine ungleichmäßige Antriebsmomentverteilung entsteht, kann das Fahrverhalten beeinflussen. Bei einem Antriebsstrang mit mehreren Motoren gibt es oftmals ein Torque-Vectoring-System, das zu einer ungleichen Verteilung der Antriebsmomente führen kann. Die Zustandsgrößen, die das System zur Berechnung der Antriebsmomentenverteilung verwendet, sind vielfältig [28]. Bei einem Antriebsstrang mit einem Motor gibt es nur im Fall von einem offenen Differential eine gleiche Antriebsmomentenverteilung zwischen den beiden Rädern der angetriebenen Achse. Verfügt das Fahrzeug über ein Sperrdifferential oder eine starre Antriebsachse, ist die Antriebsmomentenverteilung abhängig von der Sperrfunktion des Differentials sowie den Radlasten und Reibwerten an den Reifen der Antriebsachse [29, S.739].

2.1.3 Reifenmodell Pacejka Magic Formula

Das Reifenmodell ist das zentrale Bindeglied in der Fahrdynamikmodellierung. Alle anderen Teilsysteme, wie die Längs-, Quer- und Vertikaldynamik sowie die Modellierung des Antriebsstrangs, der Lenkung und des Bremssystems, bestimmen die äußeren Kräfte und Momente auf die Reifen des Fahrzeugs. Die Aufgabe der Reifenmodellierung ist es, daraus die Reaktionskräfte des Reifens zu ermitteln und in die anderen Subsysteme des Fahrzeugmodells rückzuführen [30, S.33] In der Reifenmodellierung gibt es zwei grundsätzlich verschiedene Herangehensweisen [21, S.168]:

- Mathematische/empirische Modelle
- Physikalische Modelle

Empirische Modelle basieren auf Messdaten der zu modellierenden Reifen. Diese werden entweder in Kennfelder interpoliert oder mit Hilfe einer mathematischen Funktion approximiert. Diese Form der Reifenmodellierung ist geeignet, wenn die Anregungen niederfrequenter Natur sind und die Rechenzeit ein entscheidender Faktor ist. Eine Schwäche ist, dass die Messdaten nur für die Umgebungsbedingungen valide sind, bei denen sie aufgezeichnet wurden.

Im Gegensatz dazu versuchen physikalische Modelle die Entstehung der Reifenkräfte selbst zu modellieren. Hierfür werden zwei- oder dreidimensionale Modelle oder Finite Elemente Methode (FEM)-Ansätze verwendet. Auf diese Weise sind physikalische Modelle in der Lage, transiente Situationen oder Schwingungseffekte zu modellieren. Hierfür sind jedoch oftmals höhere Rechenzeiten in Kauf zu nehmen.

Das Reifenmodell Magic Formula wurde von Pacejka [19, S.172-215] entwickelt. Es handelt sich um ein semi-empirisches Reifenmodell zur Berechnung von stationären Reifenkräften und Momenten. Es verwendet einen Ansatz der auf trigonometrischen Funktionen basiert. Abhängig von der Wahl des Eingangswert x kann als Ausgangsgröße Y die Querkraft F_y , die Längskraft F_x oder das Rückstellmoment M_R berechnet werden [30, S.40]. Mögliche Eingangsgrößen sind der Schräglaufwinkel oder der Reifenlängsschlupf.

Als Eingangsgröße zur Berechnung der longitudinalen Reifenkräfte ist der Reifenlängsschlupf λ nach DIN ISO 8855 [31] wie folgt definiert:

$$\lambda = \frac{\omega - \omega_0}{\omega_0} \quad (2.1)$$

ω_0 ist die Drehgeschwindigkeit des frei rollenden Rades, ω ist die Drehgeschwindigkeit des schlupfbehafteten Rades. Der Schlupf λ nimmt bei einem blockierenden Rad den Wert -1 an, bei einem durchdrehenden Rad kann er hohe positive Werte annehmen. Als Eingangsgröße zur Berechnung der lateralen Reifenkräfte, sowie des Rückstellmoments ist der Schräglaufwinkel α des Rads zu verwenden. DIN ISO 8855 [31] definiert den Schräglaufwinkel wie folgt:

$$S_\alpha = -\frac{v_y}{v_x} \quad (2.2)$$

$$\alpha = \arctan(S_\alpha) \quad (2.3)$$

Der Schräglaufwinkel ist die geometrische Umrechnung der Querschlufts S_α , definiert in Gleichung 2.2 als das Verhältnis des Längs- und Quergeschwindigkeitsvektor des Rades [19, S.3]. Die Geschwindigkeitskomponente v_x ist der Anteil des Reifengeschwindigkeitsvektor in Längsrichtung des Reifens. Die Geschwindigkeitskomponente v_y ist der Anteil in Querrichtung.

Die allgemeine Formulierung der Magic Formula, gültig für eine gegebene Aufstandskraft und Sturzwinkel, wird in Gleichung 2.4 bis 2.6 beschrieben [19, S.173]

$$y = D \sin(C \arctan(Bx - E(Bx - \arctan(Bx)))) \quad (2.4)$$

$$Y(x) = y(x) + S_v \quad (2.5)$$

$$x = X + S_h \quad (2.6)$$

Mit dieser Formel lassen sich verschiedene Kennlinien anpassen. Über die Koeffizienten B, C, D und E kann die Formel variabel an Messdaten der entsprechenden Zusammenhänge angepasst werden. Der Faktor D beeinflusst den Hochpunkt der Kurve. Über den Formfaktor C können die Grenzen der Sinusfunktion beschränkt werden. Der Faktor B steuert die Steigung der Kurve um

den Ursprung und wird deshalb als Steifigkeitsfaktor bezeichnet. Über den Faktor E wird die Krümmung und gleichzeitig die x-Position des Hochpunktes modifiziert. Eine Verschiebung in x oder y kann mithilfe der Faktoren S_h und S_v vorgenommen werden. Aufgrund hoher Sturzeinstellungen kann eine solche Verschiebung des Nulldurchgangs für ein F_y - α Diagramm wegen des konischem Abrollverhalten der Reifen notwendig sein. Eine Visualisierung der Einflussparameter auf das Aussehen der Kurve wird in Abbildung 2.3 gezeigt. Die Einflussparameter B-E sind keine




Abbildung 2.3: Einfluss der Koeffizienten auf die Pacejka Magic Formula [19, S.173]

festen numerischen Werte, sondern setzen sich aus weiteren Parametern zusammen. Dabei gibt es radlastabhängige, radlastunabhängige und sturzabhängige Parameter. Die Anpassung der Parameter an die vorhandenen Reifenmessdaten geschieht mithilfe von Optimierungsalgorithmen [32]. Für den Fall von kombinierten Lastzuständen mit Längs- und Queranregung des Reifens führt die Magic Formula Gewichtungsfunktionen ein. Im Fall rein eindimensionaler Belastungen sind diese Gewichtungsfunktionen auf den Wert Eins normiert. Erfolgt ein kombinierter Belastungszustand werden die ursprünglichen Kraftverläufe mit den entsprechenden Gewichtungsfunktionen multipliziert [19, S.179ff].

Kritisch kann bei der Verwendung des Pacejka-Reifenmodells für die Gesamtfahrzeugsimulation angemerkt werden, dass einige Vereinfachungen eingegangen werden. Die Messdaten zur Approximation der Funktion werden quasi-stationär aufgenommen, was zu einer eingeschränkten Verwendbarkeit des Reifenmodells führt [33]. Ergeben sich Veränderungen bei den nachfolgenden Randbedingungen führt das zu einer eingeschränkten Validität des Modells:

- ebene Fahrbahn (oder allenfalls langwellige Unebenheiten)
- konstante Geschwindigkeit der Felge in Längs- und Querrichtung (oder allenfalls kleine Beschleunigungen)
- nur langsame Änderung der Radlast und des Sturzwinkels
- konstanter Reifeninnendruck
- konstanter Fahrbahn-Reifen-Reibwert

Dazu kann es zu eingeschränkter Verwendbarkeit der Magic Formula bei geringer Fahrzeuggeschwindigkeit kommen. Die Berechnungskonvention von α aus Gleichung 2.3 und λ aus Gleichung 2.1 bedingt eine numerische Instabilität bei kleinen Fahrzeuggeschwindigkeiten.

2.2 Giermomentdiagramme

Giermomentdiagramme sind ein bekanntes Werkzeug in der Fahrzeugabstimmung, insbesondere im Rennsport. Im Gegensatz zu anderen Analysen, wie Rundenzeitsimulationen oder Tracktests, bieten sie die Möglichkeit, die Auswirkungen von Setupänderungen in Bezug auf den gesamten Betriebsbereich zu visualisieren. Sie erlauben es, ein Verständnis für die Auswirkungen auf das Fahrzeugverhalten zu entwickeln und zeigen die Kompromisse auf, die bei der Variation eines Parameters im Bezug auf Grip, Balance, Stabilität und Kontrolle eingegangen werden [34]. Das zugrundeliegende Konzept der Milliken Moment Method (MMM) zur Erstellung der Giermomentdiagramme wird in Abschnitt 2.2.1 vorgestellt. In Abschnitt 2.2.2 wird näher auf die Interpretation und die charakteristische Punkte des Giermomentdiagramms eingegangen. In Abschnitt 2.2.3 folgt eine Herleitung der Fahrzeugeigenschaften Stabilität, Kontrolle und Dämpfung aus dem Giermomentdiagramm.

2.2.1 Milliken Moment Method

Ihren Ursprung hat die MMM in Windkanaltests von Flugzeugen durch *Perkins* [35]. Von Interesse bei *Perkins'* Untersuchungen sind die resultierenden Kräfte und Momente eines Flugzeugs unter verschiedenen Rotationswinkeln. *Milliken* begründet die MMM ebenso auf der Annahme, dass die Charakterisierung von Stabilität und Kontrolle aus der Untersuchung von Kräften und Momenten auf das Fahrzeug abgeleitet werden kann. Dabei sind nicht nur die stationären Kräfte von Interesse, sondern auch Momente, die nicht im Gleichgewicht sind und zu Rotationsbeschleunigungen um die Fahrzeugachsen führen können. [14, S. 294]. Die zugrundeliegende Idee, wie die resultierenden Kräfte und Momente für eine gegebene Situation von Geschwindigkeit und Längsbeschleunigung ermittelt werden kann, wird in Abbildung 2.4 gezeigt. Bei den




Abbildung 2.4: Zugrundeliegendes Konzept der Milliken Moment Method. Fahrzeugmodell auf einer Laufrolle, gesperrt in mehreren Freiheitsgraden [14, S.295]

Untersuchungen durch *Perkins* von Flugzeugmodellen im Windkanal sind alle Freiheitsgrade komplett gesperrt. Im Gegensatz dazu, können sich bei einem Fahrzeugmodell die korrekten Radlasten nur einstellen, wenn die vertikalen Bewegungen der Reifen nicht eingeschränkt sind und das Fahrzeug die Roll-, Nick- und Wankbewegungen ausführen kann. Ziel ist es daher, nur

die Freiheitsgrade für Längs- und Querkräfte, das Moment der Reifen in Umfangsrichtung sowie das Moment um die Hochachse (Giermoment) zu sperren.

Die Einspannung, wie in Abbildung 2.4 gezeigt, besteht aus fünf Seilen. Ein Seil sperrt den Freiheitsgrad in longitudinale Richtung und nimmt die Antriebs- und Bremsmomente auf. Mithilfe von *Newtons* zweitem Gesetz in Gleichung (2.7) ist es möglich, nicht nur Situationen mit konstanter Längsgeschwindigkeit des Fahrzeugs, sondern auch Situationen mit Längsbeschleunigung zu simulieren. Die im Vergleich zu Situationen mit stationären Geschwindigkeit erhöhten Antriebsmomente bei positiver Fahrzeugbeschleunigung bzw. die Bremsmomente bei negativer Fahrzeugbeschleunigung werden durch die Einspannung in Fahrzeuginnenrichtung ausgeglichen [13].

$$F = m a \quad (2.7)$$

Ein Seilpaar greift am Schwerpunkt an, ein weiteres Seilpaar ist an der Front des Fahrzeugs angebracht. Damit wird das Fahrzeug in lateraler Richtung und um seine Hochachse gesperrt. Die Summe der Kräfte in den Seilpaaren auf einer Seite des Fahrzeugs stellt die resultierende Querkraft auf das Fahrzeug dar. Zusammen mit Gleichung (2.7) ergibt sich Gleichung (2.8) Die Kraft im vorderen Seil multipliziert mit dem Abstand zum Schwerpunkt ergibt das Giermoment, wie in Gleichung (2.9) dargestellt [14, S.295].

$$a_y = (F_{y,f} + F_{y,cog})/m \quad (2.8)$$

$$M_z = F_{y,f} l_f \quad (2.9)$$

Um ein Giermomentdiagramm mithilfe der MMM zu erstellen, wird für eine gegebene Situation aus Längsgeschwindigkeit und Längsbeschleunigung systematisch δ und β iteriert und die resultierende Querkraft und das Giermoment notiert. In Abschnitt 2.1.3 wurde gezeigt, dass die Reifenkräfte eine Funktion von F_z , α und λ sind. Dennoch ist es bei der MMM üblich die Diagramme über Kombinationen von δ und β zu simulieren, da sie die direkt messbaren Größen darstellen. Über die kinematischen Zusammenhänge aus dem Einspurmodell sind die Schräglaufwinkel direkt von δ und β abhängig wie in Gleichung (2.10) und Gleichung (2.11) gezeigt.

$$\alpha_f = \beta - \frac{l_f}{v} \dot{\psi} + \delta \quad (2.10)$$

$$\alpha_r = \beta + \frac{l_h}{v} \dot{\psi} \quad (2.11)$$

Ist der gewählte Bereich von Lenkwinkel und Schwimmwinkel breit genug gewählt, wird durch die ermittelten Daten der vollständige Zustandsraum des Fahrzeugs charakterisiert. Um die Ergebnisse zu visualisieren, sind Giermomentdiagramme die übliche Form. In der häufigsten Form der Giermomentdiagramme handelt es sich um Diagramme mit konstanter Geschwindigkeit. Auf der y-Achse wird dazu das Giermoment oder der Giermomentskoeffizient aufgetragen und auf der x-Achse die Querkraft oder Querbeschleunigung. Der Giermomentskoeffizient nach Gleichung (2.12) ist eine normierte Darstellung des Giermoments und ermöglicht die Vergleichbarkeit zwischen verschiedenen Fahrzeugen.

$$C_{M_z} = M_z / (m g l) \quad (2.12)$$

Abbildung 2.5 zeigt ein Giermomentdiagramm. Die Ergebnisse sind über Isolinien für δ und β verbunden. Jede Schnittstelle zwischen den Linien steht für ein Simulationsergebnis. In Abschnitt 2.2.2 wird detaillierter auf die Interpretation eingegangen.

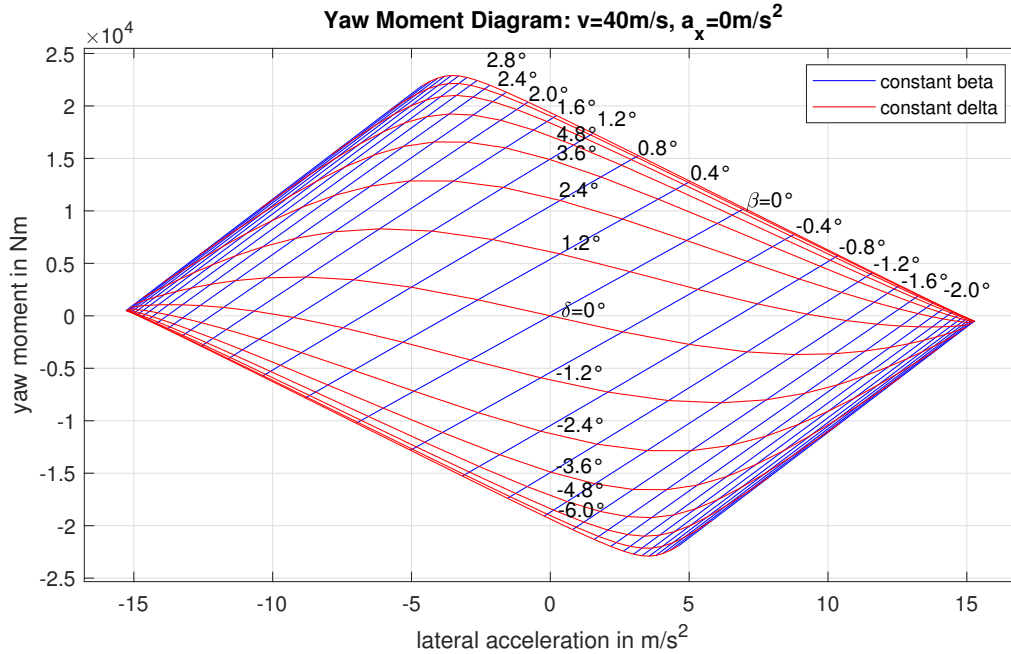


Abbildung 2.5: Typisches Giermomentdiagramm mit konstanter Geschwindigkeit

2.2.2 Bewertung des Fahrzeugverhaltens

Ein Giermomentdiagramm (GMD) kann als eine Darstellung der stationären und transienten Manövrierfähigkeit des Fahrzeug verstanden werden. Alle möglichen Zustände des Fahrzeugs liegen innerhalb der Manöverfläche. Im normalen Fahrzeugbetrieb kann kein Zustand außerhalb der Manöverfläche auftreten. Ein GMD ist unabhängig von Zeitverläufen. Dennoch kann es für das Verständnis hilfreich sein, zu visualisieren wie ein üblicher Kurvenverlauf im GMD aussieht. In Abbildung 2.6 ist eine Kurvendurchfahrt im Giermomentdiagramm dargestellt. Das Fahrzeug nähert sich in Geradeausfahrt einer Kurve mit $v_x = 40\text{m/s}$. Der Lenkwinkel wird sprunghaft auf $\delta = 1,2^\circ$ erhöht. Dadurch baut die Vorderachse Schräglauf, sowie Querkraft auf. Nach Gleichung (2.8) und Gleichung (2.9) resultiert daraus ein Giermoment, sowie eine Querbewegung. Das Giermoment führt im Zeitverlauf zu einem Schwimmwinkelaufbau. Verzögert durch die Gierträge I_z und die Gierdämpfung D_ψ stellt sich ein Schwimmwinkel $\beta = -1,2^\circ$ ein. An diesem Punkt befindet sich das Fahrzeug in der stationären Kurvenfahrt, da das Giermoment $M_z = 0\text{Nm}$ beträgt. Die stationäre Querbewegung beträgt $a_y = 9\text{m/s}^2$. Wird der Lenkwinkel wieder auf $\delta=0^\circ$ zurückgeführt, stellt sich ein negatives Giermoment ein, das das Fahrzeug wieder in die Ausgangslage zurückführt.

Aus einem GMD können eine Reihe von charakteristischen Größen ausgelesen werden. Die referenzierten Punkte sind in Abbildung 2.7 markiert.

1. **Sättigungsgrenze der Reifen:** An der Linie A sind die Vorderreifen am Hochpunkt ihrer Querkraftkurve. An der Linie B sind die Reifen der Hinterachse am Hochpunkt ihrer Querkraftkurve.




Abbildung 2.6: Verlauf einer Kurve im Giermomentdiagramm

2. **Maximale Querbearbeschleunigung:** In Punkt C tritt die maximal erreichbare Querbearbeschleunigung a_y auf.
3. **Giermoment bei maximaler Querbearbeschleunigung:** Der Punkt C liegt nicht auf der x-Achse und stellt er eine instationäre Fahrersituation dar. In diesem Fall bedeutet ein negatives Giermoment M_z im fortschreitenden Zeitverlauf eine Rückstellung im Bezug auf den Schwimmwinkel β . An dem Punkt C sind beide Achsen an ihrem Querkrafthochpunkt. Da das ausdrehende Moment der Hinterachse größer ist als das eindrehende Moment der Vorderachse, resultiert ein stabilisierendes Giermoment M_z am Querbearbeschleunigungslimit. Das Fahrzeug hat ein stabiles Grenzverhalten. Liegt der Punkt C für positive Querbearbeschleunigung über der x-Achse, neigt das Fahrzeug im Grenzbereich zu einem instabilen Verhalten mit einer Tendenz zum Eindrehen. Wie stabil oder instabil das Grenzverhalten ist, wird durch den Betrag des Giermoments im Punkt C angegeben [13].
4. **Maximale stationäre Querbearbeschleunigung:** In Punkt D tritt die maximal erreichbare Querbearbeschleunigung a_y in der stationären Kurvenfahrt ($M_z=0\text{Nm}$) auf.
5. **Maximales Giermoment:** In Punkt E tritt das maximale Giermoment M_z auf. Der Betrag des maximalen Giermoments ist ein Maß für die maximal erreichbare Gierbeschleunigung $\ddot{\psi}$ und damit für die Agilität des Fahrzeugs bei Richtungsänderungen.
6. **Stabilität:** Der Gradient F auf der δ -Isolinie bei der partiellen Ableitung von M_z , abgeleitet nach β , steht für die Stabilität des Fahrzeugs. Im folgenden Absatz wird genauer auf das Konzept von Stabilität, Kontrolle und Dämpfung eingegangen.
7. **Kontrolle:** Der Gradient G auf der β -Isolinie bei der partiellen Ableitung von M_z , abgeleitet nach δ oder a_y , abgeleitet nach δ steht für die Kontrolle des Fahrzeugs.

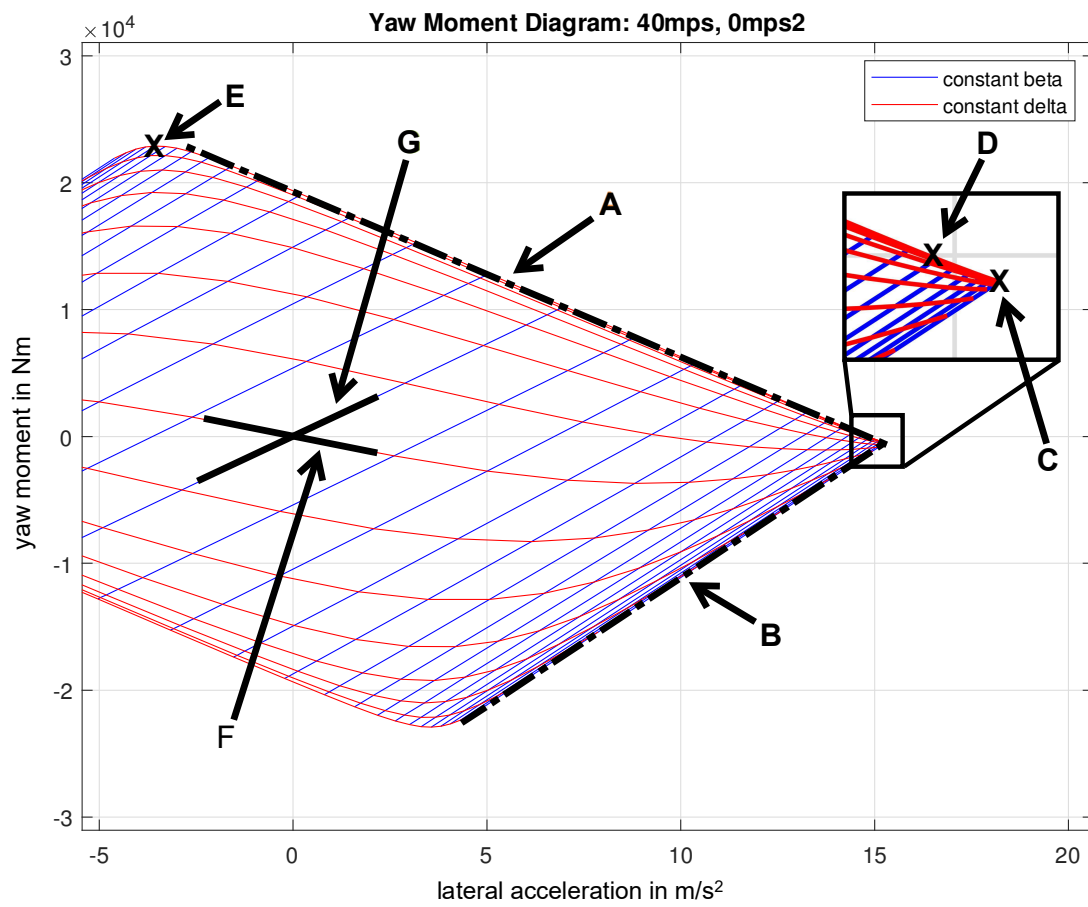


Abbildung 2.7: Charakteristische Punkte im Giermomentendiagramm

2.2.3 Stabilität, Kontrolle und Dämpfung

Zu den grundlegenden Fahraufgaben für einen Fahrer oder eine autonome Fahrsoftware gehören die Aufgaben der Führung und Stabilisierung. Die Führung bezeichnet das Folgen einer gewünschten Trajektorie. Zur Stabilisierung gehört das Abfangen von potentiell kritischen Situationen und die Rückführung in einen stabilen Fahrzustand [36, S.195-196]. Der Formel1-Fahrer Stirling Moss beschreibt das Fahrzeugverhalten beim Durchfahren einer Kurve und die Eigenschaft der Kontrolle am Limit aus der Sicht eines Fahrers: *"But once one has presented the car to a very high-speed corner it's rather like throwing a dart-when it has left your hand you can't do a thing about its path. If you present a car accurately to such a corner it will track through in a long drift on virtually a predestined trajectory. You can make tiny adjustments, but once you have presented it to the corner you can only adjust the trim, not make major changes of direction-not if you are on the limit."*[14, S.374].

Da die Bewertung des Fahrers oder der Fahrsoftware in Bezug auf die Aufgaben Führung und Stabilisierung nicht immer präzise möglich ist, hat es sich bei der Entwicklung der Fahrdynamik etabliert, die Fahrzeugkomponente herauszulösen und ihre Stabilität und Kontrollierbarkeit unabhängig vom Fahrer zu betrachten [14, S.374]. Das Fahrverhalten des Fahrzeugs kann in vier verschiedenen Kraft- und Momentreaktionen ausgedrückt werden: Kontrolle, Stabilität, Dämpfung und Störung. Die Kontrolle beschreibt, in welchem Maß in der jeweiligen Fahrsituation Änderungen am Fahrzustand herbeigeführt werden können. Die Stabilität beschreibt eine Kraftreaktion, die externen Störeinflüssen entgegengesetzt ist und das Fahrzeug in seinem Fahrzustand zurückführt. Die Dämpfung ist jeglichen Änderungen in Quer- und Giergeschwindigkeit entgegengesetzt. Eine Störung bezeichnet eine Krafteinwirkung, die das Fahrzeug von seinem aktuellen Fahrzustand abzubringen versucht [14, S.374-375]. Wie bei technischen Systemen häufig der Fall, sind die Eigenschaften Reaktionsfähigkeit und Stabilität einander entgegengesetzt [37].

Milliken führt die Querkraft- und Giermomentableitungen zum Beschreiben dieser Fahrzeugreaktionen ein. Diese können aus den Beziehungen des linearen Einspurmodells hergeleitet werden [14, S.123-191]. Soll die Ableitung im nichtlinearen Bereich geschehen, so bietet sich die Herleitung über partielles Differenzieren der Giermomentdiagramme an, sofern ein nichtlineares Fahrzeugmodell zur Simulation verwendet wurde. Dabei können die Querbeschleunigung und das Giermoment nach dem Lenkwinkel und dem Schwimmwinkel abgeleitet werden. Daraus ergeben sich die durch *Milliken* beschriebenen Ableitungen [13, S.152-153]:

- $\frac{\partial a_y}{\partial \delta}$ **Kontrollkraft-Ableitung:** Diese Ableitung ist der Proportionalitätsfaktor zwischen der Querbeschleunigung und dem Lenkwinkel und stellt ein Maß für die Beschreibung der Kontrolle dar. Die Ableitung der Kontrollkraft ist bis zum Querkraftmaximum positiv und wird zu Null, wenn die Vorderreifen ihr Querkraftlimit erreichen. Eine Erhöhung des Lenkwinkels kann an diesem Punkt die Querbeschleunigung nicht weiter erhöhen.
- $\frac{\partial M_z}{\partial \delta}$ **Kontrollmoment-Ableitung:** Diese Ableitung ist der Proportionalitätsfaktor zwischen dem Giermoment und dem Lenkwinkel und stellt ein Maß für die Beschreibung der Kontrolle über die Rotationsbeschleunigung des Fahrzeugs dar. Analog zur Kontrollkraft-Ableitung wird die Kontrollmoment-Ableitung zu Null, wenn die Vorderreifen ihr Querkraftlimit erreichen. Im Gegensatz zur Kontrollkraft-Ableitung kann die Kontrollmoment-Ableitung weiter gesteigert werden, wenn die Hinterachse mit höheren Schräglaufwinkeln als an ihrem Querkraftmaximum betrieben wird,

da das reduzierte stabilisierende Giermoment der Hinterachse das Giermoment des Fahrzeugs erhöht.

- $\frac{\partial M_z}{\partial \beta}$ **Stabilitätsmoment-Ableitung:** Diese Ableitung ist der Proportionalitätsfaktor zwischen dem Giermoment und dem Schwimmwinkel. Es ist das Maß für die Open-Loop-Stabilität der Fahrsituation. Steigt das destabilisierende Giermoment der Vorderachse in einem geringeren Gradient als das stabilisierende Moment der Hinterachse, ist das Fahrzeug stabil. Das Fahrzeug reagiert auf Störungen des Schwimmwinkels entgegengesetzt zur Störung, so dass sich bei ansonsten konstanten Eingangsgrößen (Lenkwinkel, Antriebs- & Bremsmoment) im zeitlichen Verlauf eine stabile Fahrsituation einstellt. *Milliken* verwendet zu Veranschaulichung das Verhalten eines Wetterhahns im Wind, der bei einer Auslenkung durch die aerodynamischen Kräfte auf die Seitenwand wieder in seine Ursprungsposition zurückschwenkt [13]. Ist die Stabilitätsmoment-Ableitung negativ, wird sich ohne Gegenreaktion der Schwimmwinkel unkontrolliert erhöhen. Negative Stabilitätsmoment-Ableitungen treten vor allem im Bereich des Querkraftmaximums der Hinterachse auf.
- $\frac{\partial a_y}{\partial \beta}$ **Schwimmwinkeldämpfungs-Ableitung:** Diese Ableitung ist der Proportionalitätsfaktor zwischen der Quereschleunigung und dem Schwimmwinkel. Die Interpretation ist vergleichbar mit der Schräglaufsteifigkeit eines Reifens, jedoch sinngemäß für das gesamte Fahrzeug. Da die Ableitung für den Fahrzeugbetrieb unterhalb des Querkraftmaximums der Reifen negativ ist (positive Quereschleunigung bei negativer Quergeschwindigkeit), verhält sie sich analog zu einem Lineardämpfer und wird daher als Schwimmwinkeldämpfungs-Ableitung bezeichnet.

Die Interpretation der Kontrollableitungen ist verhältnismäßig trivial. Nehmen diese hohe Werte an, so sind Lenkeingriffe in Bezug auf die Quereschleunigung oder das Giermoment sensitiv. Nehmen die Kontrollableitungen den Wert Null an, befindet sich das Fahrzeug in der durch Moss beschriebenen „*vorbestimmten Trajektorie*“ und eine Steigerung des Lenkwinkels kann keine Giermomenterhöhung bewirken. Bei der Deutung der Stabilitätsableitung stellt sich die Frage, inwiefern eine negative Stabilität zu einer kritischen Situation mit Kontrollverlust über das Fahrzeug führt. *Inagaki et al.* konnten mit Hilfe von Phasenportrait-Analysen erkennen, dass geübte Fahrer im Grenzbereich das Fahrzeug in Open-Loop instabilen Fahrzuständen betreiben, was für ungeübte Fahrer nicht möglich ist [38]. *Yi et al.* zeigten das professionelle Fahrer bei der Ausübung der Scandinavian Flick-Technik in Bereichen mit instabilen Fahrzeugverhalten operierten und dadurch die Agilität, quantifiziert durch Änderung der Quereschleunigung, signifikant steigern konnten [39]. Durch diese Beispiele wird gezeigt, dass geübte Fahrer in der Lage sind instabile Fahrsituationen bei Bedarf zu stabilisieren. *Kegelmann* weist darauf hin, dass Trajektorienplanungsalgorithmen, die auf dem *Kamm'schen Kreis* oder Abwandlungen basieren, das Konzept von Stabilität nur eingeschränkt berücksichtigen. [40, S.13] Dabei zeigt er in seiner Arbeit auf, dass ein erfahrener menschlicher Fahrer gegenüber einem autonomen Fahrzeug eine bessere Kurvenperformance erreichen konnte, weil er die Hinterachse näher an Querkraftmaximum betrieben konnte. Das erfordert die Fähigkeit das Fahrzeug bei Bedarf effizient und schnell stabilisieren zu können [40, S.126]. Der Bereich negativer Stabilität ist daher nicht als grundsätzlich kritisch zu interpretieren. Zur Rundenzeitminimierung kann das zeitweise Operieren in instabilen Fahrzuständen sogar notwendig sein, um das maximale Potential aller Reifen auszuschöpfen. Dabei kann die Kenntnis über die Stabilität für die Weiterentwicklung von autonomer Fahrzeugsoftware eine wertvolle Erweiterung darstellen.

2.3 Ermittlung des Fahrbahn-Reifen-Reibwerts

Der Reifen ist ein komplexes, nichtlineares System und seine Eigenschaften zu beschreiben gehört zu den komplexeren Forschungsgebieten im Bereich der Fahrzeugtechnik. Daher wird in Abschnitt 2.3.1 zuerst auf die zugrundeliegenden Mechanismen der Fahrbahn-Reifen-Reibung eingegangen, um zu verstehen, wie Reifenkräfte aufgebaut werden. In Abschnitt 2.3.2 wird das typische Reifenverhalten in Form von F_y - α Diagrammen beschrieben und es erfolgt eine Diskussion über die Veränderung des Reifenverhaltens bei Reibwertveränderungen. Da der Reibwert nicht gemessen, sondern nur indirekt geschätzt werden kann, folgt in Abschnitt 2.3.3 eine Klassifizierung mit Betrachtung der Vor- und Nachteile von verschiedenen Ansätzen zur Reibwertschätzung. Die Bedeutung der Reibwertschätzung in Kontext von autonomen Fahrzeugen wird in Abschnitt 2.3.4 aufgezeigt und setzt damit den Rahmen im späteren Teil der Arbeit, ab Kapitel 5.

2.3.1 Mechanismen der Fahrbahn-Reifen-Reibung

In der durch *Kummer* [41] veröffentlichten, vereinheitlichten Gummireibungstheorie werden die zwei primären Effekte beschrieben, die bei der Übertragung der Reifenkräfte zu beobachten sind. Die Reibungskraft F_R setzt sich zusammen aus der Adhäsionsreibung und der Hysteresereibung nach

$$F_{\text{Reibung}} = F_{\text{Adhäsion}} + F_{\text{Hysteresese}} \quad (2.13)$$

Sekundäre Effekte, wie die Kohäsionsreibung und die Viskosereibung, können vernachlässigt werden [42, S.55]. Diese Reibungsfälle sind nur für die Betrachtung von Aquaplaning oder im Fall von deintegrierenden Reifen relevant [43, S.40].

Die Adhäsionsreibung beschreibt die Entstehung von direkten Verbindungskräften zwischen Fahrbahn und Reifen durch *Van-der-Waals*-Kräfte. Damit diese Kräfte entstehen können, muss direkter Kontakt zwischen Reifenoberfläche und Fahrbahnoberfläche bestehen (Abstand $< 10^{-5} \text{ mm}$) [44, S.18]. Befinden sich weitere Medien wie Öl oder Wasser zwischen Reifen und Fahrbahn, wird die Adhäsionsreibung reduziert. Die Adhäsionskomponente ist maßgeblich abhängig von den Materialeigenschaften der Gummimischung und der Fahrbahnbeschaffenheit. Die Adhäsionsreibung ist am größten auf trockenen, glatten Fahrbahnen, weil hier die Kontaktfläche am größten ist [42, S.55]. Ist die Fahrbahn nass, so ist die Fähigkeit zur Ausbildung von Adhäsionskräften von den Drainagefähigkeiten des Reifens durch Profilierung abhängig. Kann genug Wasser zwischen Reifenoberfläche und Fahrbahn verdrängt werden, können sich Adhäsionskräfte ausbilden [42, S.55]. Einfluss auf die Adhäsionsreibung haben ebenfalls der Kontaktdruck p_z , die Gleitgeschwindigkeit v und die Temperatur T [43, S.38]. Die Kontaktfläche zwischen Reifen und Fahrbahn vergrößert sich über den zunehmenden Kontaktdruck. Da die Aufstandsfläche durch ein Maximum begrenzt ist, lässt sich durch den Umstand der degressive Anstieg des Reifenreibwerts mit zunehmender Radlast F_z erklären [43, S.38]. Die Hysteresereibung beschreibt den Verzahnungseffekt zwischen Reifen und Fahrbahn und wird durch das viskoelastische Werkstoffverhalten von Gummi bestimmt. Damit sich Hysteresereibung ausbilden kann, muss eine ausreichende Straßenrauigkeit von $0,001 - 10 \text{ mm}$ vorliegen [45]. Durch die viskoelastischen Eigenschaften von Reifen führt das Gleiten eines Reifenprofilstreifens über Fahrbahnunregelmäßigkeiten dazu, dass sich vor der Fahrbahnunregelmäßigkeit in der Reifenoberfläche ein Druckkegel aufbaut. Aufgrund der viskoelastischen Materialdämpfung kann nach




Abbildung 2.8: Adhäsionsreibung und Hysteresereibung: Darstellung der Reibungseffekte. v steht für die Richtung der Gleitgeschwindigkeit, nicht für die Fortbewegungsrichtung des Fahrzeugs. [42, S.56]

dem Übergleiten der Unregelmäßigkeit der Reifen nicht sofort in seinen unverformten Zustand zurückgehen, sodass der Druckkegel auf der Rückseite der Unregelmäßigkeit kleiner ausgeprägt ist. Abbildung 2.8 visualisiert diesen Effekt und stellt die Adhäsionsreibung im Vergleich dazu dar. Die Hysteresereibung ist entgegen der Adhäsionsreibung nicht von einem direkten Kontakt zwischen Reifen und Fahrbahn abhängig und wird deshalb zum primären Reibungseffekt bei nasser oder anderweitig bedeckter Fahrbahn [42, S.55]. Wesentlichen Einfluss auf die Hysteresereibung hat die Anzahl der lokalen Rauigkeitsspitzen, der Kontaktdruck p_z , die Gleitgeschwindigkeit v , die viskoelastische Dämpfung und die Temperatur T . Mit steigender Gleitgeschwindigkeit vergrößern sich die Druckunterschiede um die Fahrbahnunregelmäßigkeit und führen zur Steigerung der Hysteresereibung. Steigt die Gleitgeschwindigkeit zu stark, verhärtet sich der Gummi aufgrund seiner viskoelastischen Eigenschaften, was die Eindringtiefe in Straße und die Reibung reduziert [43, S.39]. Das Maximum der Hysteresereibung liegt in Abhängigkeit der Materialeigenschaften im Bereich von $v_{\mu max} = 0.1 - 0.5 \text{ m/s}$ [41, S.165 ff.]. Ist die viskoelastische Dämpfung der Gummimischung hoch, führt das zu größeren Druckunterschieden vor und hinter der Fahrbahnunregelmäßigkeit und demnach zu einem hohen Hysteresereibanteil. Ist die Temperatur unterhalb der Glasübergangstemperatur des Reifenmaterials verliert der Reifen seine viskoelastischen Eigenschaften und kann keine Verzahnung zum Untergrund mehr herstellen. Winterreifen verfügen aus diesem Grund über eine Gummimischung mit niedrigerer Glasübergangstemperatur.

2.3.2 Veränderung des Reifenverhaltens bei wechselnden Fahrbahn-Reifen-Zuständen

Das Kraftübertragungsverhalten eines Reifens hängt von der Fahrbahn-Reifen-Verbindung im Reifenlatsch ab. Der Reifenlatsch ist die Kontaktfläche zwischen Reifen und Fahrbahn. Zur Beschreibung der Reifenreaktionskräfte kann als Zusammenfassung der Mechanismen aus Abschnitt 2.3.1 der Reibungskoeffizient μ verwendet werden, wenn er als richtungsabhängige Größe mit unterschiedlichen Werten für μ für die Längs- und Querrichtung verwendet wird [46, S.17]. Die Reaktionskraft des Reifens berechnet sich durch

$$F_{x,y} = F_N \mu_{x,y} \quad (2.14)$$

Die Aufstandskraft F_N wirkt auf die Fahrbahnebene, die richtungsabhängigen Reaktionskräfte $F_{x,y}$ wirken in der Fahrbahnebene [47, S.8]. Dabei ist die der Reibwert μ kein konstanter Wert, sondern abhängig vom Anregungszustand des Reifens. Die Anregung in Längsrichtung wird durch den Schlupf λ nach Gleichung 2.1 ausgedrückt. Der Schräglaufwinkel ist die geometrische Umrechnung der Querschlufts S_α , definiert in Gleichung 2.2 als das Verhältnis des Längs- und Quergeschwindigkeitsvektor des Rades [19, S.3]. Obwohl die Verwendung der Querschlufts aufgrund seiner Analogie zum Längsschlupf λ naheliegend wäre, hat sich die Verwendung des Schräglaufwinkel α als Maß für die Queranregung des Reifens aus praktischen Gründen durchgesetzt [42, S.62].

Zur Beschreibung der querdynamischen Eigenschaften eines Reifens ist die Verwendung des F_y - α Diagramm üblich. In Abhängigkeit der Radlast und des Sturzes wird in den F_y - α Diagrammen die Querkraft in Abhängigkeit des anliegenden Schräglaufwinkels dargestellt.




Abbildung 2.9: Beispielhaftes F_y - α Diagramm für die Reifen des Devbot bei einer anliegenden Reifen-normalkraft von $F_z = 5000N$

Drei Eigenschaften des in Abbildung 2.9 gezeigten, exemplarischen F_y - α Diagramms sind von Interesse:

- Die Schräglaufsteifigkeit C_α im Nulldurchgang der Kurve, angegeben in N/deg . Die Schräglaufsteifigkeit nahe des Ursprungs ist für das lineare Fahrzeugverhalten relevant [19, S.1].
- Der maximale Reifenreibwert μ_{max} angegeben als einheitsloser Wert. Er ergibt sich durch die Division der Querkraft F_y durch die anliegende Radlast F_z . Im Kontext des Gesamtfahrzeugs limitiert der maximale Reifenreibwert über alle vier Reifen die maximale Querbeschleunigung a_y
- Die α -Position des maximalen Reifenreibwerts. Die Position des Hochpunkts der Querkraftkurve ist in der Betrachtung des Gesamtfahrzeugs relevant, weil sie Einfluss auf den Fahrzustand am Querbeschleunigungsmaximum hat. Der Schwimmwinkel β und der Lenkwinkel δ am Querbeschleunigungsmaximum des Fahrzeugs wird sich verändern, wenn der sich Hochpunkt der Querkraftkurve in seiner α -Position verschiebt. Das kann durch die Giermomentdiagramme in Abschnitt 2.2.2 nachgewiesen werden.

Von besonderem Interesse ist in dieser Arbeit der maximale Reibwert, da daraus nach Gleichung 2.15 die maximal übertragbare Reifenkraft abgeleitet werden kann.

$$F_{max} = F_N \mu_{max} \quad (2.15)$$

Eine Veränderung des maximalen Reibwertes kann aus unterschiedlichsten Ursachen erfolgen. Die folgende Auflistung zeigt Einflussfaktoren, die während des Fahrbetriebs zu einer Veränderung des maximalen Reibwertes führen können. Ursachen in der Veränderung der Fahrzeugkonfiguration, wie z. B. der Wechsel der Bereifung auf einen anderen Reifentyp, bleiben unberücksichtigt. Mögliche Ursachen für eine Veränderung des Reibwertes umfassen: [19, 43, 45, 48]:

- Reifen- und Fahrbahntemperaturen
- Reifeninnendruck
- Radlast
- Radsturz
- Reifenabnutzungszustand
- Mikro- und Makrorauigkeit der Fahrbahnoberfläche
- Fahrbahnkrümmung
- weiteres Medium auf der Fahrbahnoberfläche, wie z.B. Wasser, Sand, Reifenabrieb, Schnee, etc.

Verändert sich der maximale Reibwert, hat das Auswirkungen auf den Verlauf des F_y - α Diagramms. Dabei ist die Auswirkung einer Veränderung des maximalen Reibwertes auf die Schräglaufsteifigkeit bei geringen Schräglaufwinkeln nicht abschließend geklärt. Einige Literaturbeispiele beziehen sich auf Studien zu längsdynamischen Reifeneigenschaften, zu denen es mehr Forschungsergebnisse gibt. Die grundsätzliche qualitative Übertragbarkeit auf das querdynamischen Reifenverhalten wird aufgrund der vergleichbaren Wirkmechanik der Anregung unterstellt.

Carlson und *Gerdas* [49] zeigen in ihren Untersuchungen zur konsistenten Schätzung der Reifenschlupfsteifigkeit, dass diese bei geringen Schlupfwerten stark von den Parametern Reifendruck, Reifenprofiltiefe, Reifenaufstandskraft und Temperatur abhängig ist. Interessanterweise zeigte die Bewässerung der Fahrbahn im Vergleich den kleinsten Einfluss.

Andrieux et al. [50] kommen zu dem Ergebnis, dass sich bei der Variation von unterschiedlichen Fahrbahnoberflächen und Reifenabnutzungszustände keine Korrelation zwischen Schlupfsteifigkeit und maximalen Reibwert erkennen lässt. Dazu wurden Daten von 5 verschiedenen Fahrbahnoberflächen und acht verschiedenen Reifen mithilfe von Schlupf und Beschleunigungsmessungen verglichen.

Albinsson et al. [51] untersuchten die Verwendung von aktiver Reifenkraftanregung zur Reibwertschätzung. Aus ihren Messdaten geht hervor, dass die Variation des Untergrunds von einer nassen Asphaltoberfläche zu Schotter die Schlupfsteifigkeit reduziert und den Hochpunkt der Querkraftkurve auf einen höheren Schlupfwert verschiebt.

Hüsemann zeigt in seiner Arbeit, dass unterschiedliche Fahrbahnuntergründe Auswirkungen auf die Schräglaufsteifigkeit, den maximalen Fahrbahn-Reifen-Reibwert und das Rückstellmoment des Reifens haben. Er entwickelt eine Methode zur Skalierung von Reifendaten von Prüfständen

auf reale Fahrbahnen über Skalierungsfaktoren [43, S. 156]. *Hüsemann* kommt zu dem Schluss, dass der wesentliche Einfluss auf die Schräglaufsteifigkeit des Reifens von der Krümmung der Prüfstandfahrbahn ausgeht. Unterschiede durch Prüfstandsoberflächen mit verschiedenen Reibwerten auf die Schräglaufsteifigkeit konnten nicht festgestellt werden [43, S. 97]. Kritisch ist anzumerken, dass sich *Hüsemann* zwar auf die Skalierung der initialen Schräglaufsteifigkeit bei Schräglaufwinkeln nahe $\alpha = 0^\circ$ und auf die des maximalen Fahrbahn-Reifen-Reibwert eingeht, aber nicht auf die α -Position des Reibwertmaximums. Dabei ist aus seinen Aufzeichnungen ersichtlich, dass unterschiedliche Fahrbahnmaterialien einen Einfluss auf die α -Position des Reibwertmaximums haben.

Abseits von empirischen Untersuchungen gehen bekannte Reifenmodelle ebenfalls unterschiedlich mit skalierten maximalen Reifenreiwerten um. *Riberio et. al.* [52] zeigen in ihrer Arbeit, dass die Reifenmodelle von *Pacejka*, *Dugoff* und das *Brush-Modell* bei der Skalierung des Reibungskoeffizienten über die integrierten Skalierungsparameter der Modelle unterschiedliche Reifenkurven in Bezug auf die C_α und den α -Wert des Hochpunktes erzeugen. Das *Pacejka* Modell zeigt in Abbildung 2.10 bei veränderlichem Reibwert keine Auswirkung im Bezug auf die Schräglaufsteifigkeit, die α -Position des maximalen Reibwerts verschiebt sich hingegen deutlich. Im *Brush-Modell* ist die Auswirkung des maximalen Reibwerts auf die beiden anderen Charakteristika gering. Im *Dugoff* Modell ist ein Einfluss auf die Schräglaufsteifigkeit und auf den α -Wert des Hochpunktes zu erkennen. Zu Beantwortung der Frage, wie sich ein veränderlicher

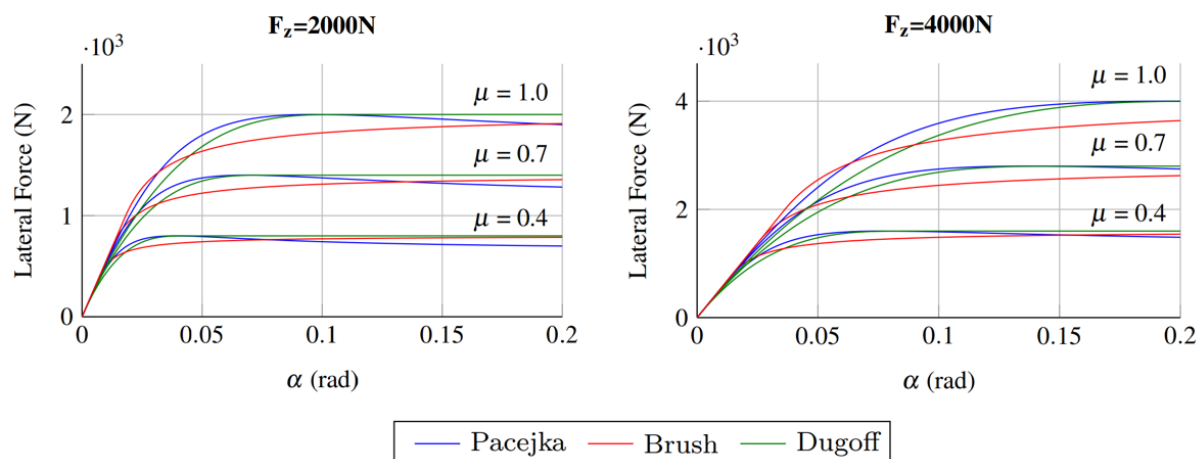


Abbildung 2.10: Veränderung der Reifenquerkraftkurve bei Veränderung des maximalen Reibwertes. Ein Vergleich der Reifenmodelle nach Pacejka, Dugoff und des Brush Modells. [52]

maximaler Reibwert auf den qualitativen Verlauf der F_y - α Diagramme auswirkt, kann keine eindeutige Antwort gefunden werden. Die verschiedenen Einflussfaktoren auf den maximalen Reifenreiwert scheinen unterschiedliche qualitative Auswirkungen auf den Verlauf zu haben. Zum Beispiel könnte eine bewässerte Fahrbahn oder Rollsplitt auf der Fahrbahn zu einem identischen maximalen Reibungskoeffizienten führen, jedoch mit verschiedenen Auswirkungen auf die Schräglaufsteifigkeit und die α -Position des Querkraftmaximums. Daraus folgt: Ist die Ursache der Reibwertveränderung nicht *a priori* bekannt, ist es nicht möglich nur über die Kenntnis des neuen maximalen Reibwerts auf den Verlauf der F_y - α Kurve zu schließen.

2.3.3 Methoden zur Reibwertschätzung

Aufgrund der Tatsache, dass der maximale Fahrbahn-Reifen-Reibwert nur indirekt messbar ist, gibt es bereits eine Vielzahl an Methoden zur Reibwertschätzung mit unterschiedlichen

Ansätzen. Zur Zeit existiert keine universell verwendete Methodik zur Reibwertschätzung, da die Wahl von Faktoren, wie verfügbarer Sensorik und Anforderung der Anwendung abhängig ist. Im Kontext dieser Arbeit ist die Schätzung des maximalen Reibwerts von besonderem Interesse.

Bei der Klassifizierung der vorhandenen Methoden gibt es unterschiedliche Ansätze. *Khaleghian et al.* unterteilen die Methoden in experimentbasiert und modellbasiert [16]. Experimentelle Ansätze versuchen eine Korrelation zwischen Sensordaten (Kamera, Mikrofon, Temperatursensoren, etc.) und Parametern zu finden, die den Reibungswert verändern. Ein Beispiel ist die Klassifizierung von nassen oder vereisten Straßen über eine Kamera und die Zuordnung eines Reibwerts. Zu den modellbasierten Methoden gehören die Modellierung von Reifen oder des Fahrzeugs sowie die Verarbeitung von Fahrdaten zur Schätzung von Reibwerten.

Acosta et al. sprechen von einer Einteilung in ursachenbasierten und effektbasierten Ansätzen [17]. Ursachenbasierte Ansätze fokussieren sich auf eine Schätzung des Reibwerts auf Basis der wahrnehmbaren äußeren Umstände, wie beispielsweise dem Fahrbahnzustand, und überschneiden sich thematisch mit der Definition der experimentbasierten Ansätzen von *Khaleghian et al.*. Effektbasierte Ansätze basieren auf der Messung von fahrdynamischen Größen und der Interpretation mithilfe von Modellen. Wegen der geringen Unterschiede in der Klassifikation zwischen *Acosta et al.* und *Khaleghian et al.* und der häufigeren Verwendung in weiterer Literatur [50, 51, 53] wird im Folgenden von ursachen- und effektbasierten Ansätzen gesprochen.

Ursachenbasierte Ansätze haben gegenüber effektbasierten Ansätzen den Vorteil, dass sie Reibungswerte auf dem Straßenabschnitt vor dem Fahrzeug abschätzen können und eine Antizipation ermöglichen. Die Fähigkeit hängt jedoch von der Menge und Qualität der Referenzdaten ab [17]. Ein weiterer Nachteil dieser Ansätze ist, dass zusätzliche Sensoren erforderlich sind [54].

Effektbasierte Ansätze haben in der Forschung in den letzten Jahren aufgrund ihrer Robustheit und Kosteneffizienz eine größere Aufmerksamkeit erfahren [17]. Die Vorstellung der Ansätze in diesem Kapitel beschränkt sich deshalb auf effektbasierte Ansätze.

Im Bereich der effektbasierten Ansätze können die existierenden Methoden in drei Unterkategorien eingeteilt werden: Slip-Slope, modellbasiert und datenbasiert.

Die Slip-Slope-Ansätze gehen von der Annahme aus, dass der maximale Reibwert des Reifens als eine Funktion der Schlupfsteifigkeit C_λ ausgedrückt werden kann [55].

$$\mu_{max} = f(C_\lambda) \tag{2.16}$$

Dadurch kann bereits durch geringe longitudinale Anregung auf den maximalen Reibwert μ_{max} geschlossen werden. Eine Vielzahl von Arbeiten verwenden den Slip-Slope Ansatz [56–59]. Die Slip-Slope-Ansätze sind allerdings umstritten. Unter anderem sind sie schwer zu reproduzieren [60] und es zeigt sich, dass kein allgemeingültiger Zusammenhang in Bezug auf die Schlupfsteifigkeit und der Variation der Reifen-Untergrund-Kombination gefunden werden kann [50]. *Acosta et al.* kommen zu dem Schluss, dass Slip-Slope-Ansätze für starke Änderungen im maximalen Reibwert verwendbar sind. Unterschiede im Reibwert zwischen verschiedenen festen Untergründen hingegen nicht zuverlässig erkennen können [17].

Im Bereich der Ansätze zur Reibwertschätzung durch laterale Anregung finden sich hauptsächlich modellbasierte Ansätze. Charakteristisch verbindet diese Ansätze, dass aus der Abweichung zwischen gemessenen und durch das Modell berechneten Größen ein Rückschluss auf den maximalen Reibwert ermöglicht wird. Verwendete Modelle umfassen empirische und physikalische Reifenmodelle, so wie Ein- oder Zweispurmodelle.

Im Folgenden werden drei Beispiele vorgestellt, die dem in dieser Arbeit vorgeschlagenen Algorithmus konzeptionell nahe sind:

Wang et al. [61] schlagen eine Beobachter zur Schätzung der Quergeschwindigkeit v_y und dem maximalen Reifenreibwert μ_{max} vor. Die Schätzung des maximalen Reifenreibwert μ_{max} wird durch *Wang et al.* auf den nichtlinearen Reifenbereich beschränkt, da darunter die Schräglaufsteifigkeit C_α als unabhängig vom Reibwert angenommen wird. Die Schätzung erfolgt mit Hilfe des resultierenden Querkraftfehlers aus der Messung und einem Pacejka Magic Formula Reifenmodell. Der Operationsbereich der Schätzung ist limitiert auf Fahrsituationen mit geringen longitudinalen Reifenkräften.

Choi et al. [62] schlagen einen Algorithmus zur simultanen Schätzung der Reifenlängs- und quersteifigkeit (C_λ, C_α) sowie dem maximalen Reifenreibwert μ_{max} vor. In dem Algorithmus werden die Reifenkräfte sowie die Werte für Schräglauf α und Schlupf λ in separaten Blöcken durch eine linearisierte, rekursive Methode der kleinsten Quadrate über ein Brush-Reifenmodell geschätzt.

Wang et al. [63] verwenden in einer weiteren Arbeit den geschätzten Schräglaufwinkel α und Schlupf λ der vier Reifen als Eingangsgröße, um mithilfe eines Brush-Reifenmodells die richtungsabhängigen maximalen Reifenreibwerte $\mu_{x,max}$ und $\mu_{y,max}$ zu erhalten. Mit Hilfe einer Gewichtungsfunktion wird durch die Autoren ein Verfahren vorgeschlagen, um die richtungsabhängigen Reibwerte zu einem richtungsunabhängigen Reibwert zu verschmelzen.

Die modellbasierten Ansätze verbindet eine grundsätzliche Abhängigkeit von der Parametrierung der Modelle. Dadurch ergibt sich ein Validitätskorridor im Bezug auf die Zustandsgrößen und Umgebungsbedingungen.

Datenbasierte Algorithmen versuchen unabhängig von Fahrzeug- oder Reifenmodellen eine Zuordnung von Fahrzeugzustandsgrößen zu einem Reibwert zu finden. Häufig wird auf die Anwendung von Neuronalen Netzen zugegriffen, wie die Ansätze von *Song et al.* [64] und *Acosta und Kanarachos* [65] zeigen.

2.3.4 Reibwertschätzung im Anwendungsfall autonomer Rennfahrzeuge

Reibwertschätzung wie in Abschnitt 2.3.3 vorgestellt, hat ihren Ursprung in den Fahrdynamikregelsystemen, wie Antiblockiersystem (ABS) oder Elektronisches Stabilitätsprogramm (ESP). Hierbei wird der Längsschlupf des Reifens λ überwacht, um ein Blockieren der Räder im Bremsfall zu verhindern oder über gezielte Bremseingriffe an einzelnen Rädern das Fahrzeug in instabilen Fahrsituationen zu stabilisieren [66, S.181-196]. Durch ihre interne Überwachung nehmen diese Algorithmen bereits eine Schätzung des Reibwertes vor. Eine Schätzung liegt aber nur im Fall der Auslösung des Systems und demnach bei einer hohen Anregung des Reifens vor. Sind die Systeme nicht aktiv oder erfolgt kein Regeleingriff, liegt keine Schätzung zum Reibwert vor.

Durch den verstärkten Einzug von Advanced Driver Assistance Systems (ADAS) rückt die kontinuierliche und vorausblickende Schätzung von Reibwerten vermehrt in den Fokus. Teilautonome Funktionen wie beispielsweise das Autonomous Emergency Braking (AEB) System, sind direkt von der Kenntnis des maximalen Reibwerts abhängig, um ihre Time-To-Collision (TTC) zu berechnen und den Bremszeitpunkt passend zu setzen [67]. Dabei hängt es von der Qualität der Reibwertschätzung ab, dass der Bremseneingriff weder zu früh noch zu spät eingeleitet wird [68]. Für autonome Rennfahrzeuge, wie den Devbot aus der Roborace-Serie (Abbildung 2.11)



Abbildung 2.11: Das Fahrzeug Devbot des TUM Autonomous Racing Team in der Rennserie Roborace [69]

oder den autonomen Dallara IL-15 (Abbildung 1.1), hat die Reibwertschätzung nicht nur bei der Fahrzeugregelung, sondern bereits bei der Planung der Trajektorie eine hohe Bedeutung. *Heilmeier et al.* präsentierten in Ihrer Arbeit einen zweistufigen Algorithmus zur Planung von Trajektorien für autonome Rennfahrzeuge zur Minimierung von Rundenzeiten [70]. Zunächst wird eine Trajektorie mit einer minimalen Krümmung berechnet und dann ein geeignetes Geschwindigkeitsprofil erzeugt, dass die durch Gleichung (2.17) gegebenen Beschleunigungsgrenzen des Fahrzeugs einhält.

$$v_{max} = \sqrt{\frac{a_y}{\kappa}} \quad (2.17)$$

Es ist ersichtlich, dass die Zielgeschwindigkeit v_{max} direkt vom gegebenen Quereschleunigungslimit a_y abhängig ist. Bei der Trajektorienplanung ist es daher von Vorteil, nicht den Reibwert eines einzelnen Rades, sondern die Quereschleunigungsgrenze des gesamten Fahrzeugs zu kennen. Wie bereits in Abschnitt 2.2.2 gezeigt wurde, ist die maximale stationäre Quereschleunigung auch vom Fahrzeugsetup abhängig, sodass trotz konstantem Reifenreiwert unterschiedliche stationäre Quereschleunigungen durch Änderung des Fahrzeugsetups erreicht werden können.

2.4 Machine Learning Verfahren zur Regression

Auf dem Gebiet des Machine Learning (ML) herrscht eine Menge Aktivität in der Wissenschaft. Es ist ein Teilgebiet der Artificial Intelligence (AI) dessen Ziel es ist, Maschinen intelligent handeln zu lassen. Hierfür gibt es viele verschiedene Ansätze. Der Ansatz von ML ist dadurch definiert, dass die Maschine selbstständig lernt eine bestimmte Aufgabe auszuführen [71, S.3]. Im Bereich des ML sind Einflüsse aus vielen verschiedenen Disziplinen, wie Statistik, Hirnforschung, Psychologie, Evolutionstheorie und Regelungstechnik zu erkennen [72, S.3-4]. In Abschnitt 2.4.1 ein Überblick über den Bereich des ML gegeben und ausgewählte Verfahren zur Anwendung bei Regressionsproblemen vorgestellt. In Abschnitt 2.4.2 wird ein Überblick über die gängigen Metriken zu Evaluierung der Leistungsfähigkeit eines ML-Algorithmus gegeben.

2.4.1 Vorstellung ausgewählter Verfahren

So unterschiedlich die bestehenden Ansätze für ML sind, gibt es drei charakteristische Gemeinsamkeiten, die beschrieben werden können [73, S.4]:

1. Der ML-Algorithmus verarbeitet Datensätze zu Informationsgewinnung.
2. Der Fehler oder ein Maß für die Distanz zum optimalen Verhalten wird durch den Algorithmus ausgedrückt.
3. Über eine Feedback-Schleife passt sich der Algorithmus an und optimiert sein Verhalten für die zukünftige Anwendung.

Anwendung finden ML-Algorithmen bereits in vielen Bereichen des täglichen Lebens, wie beispielsweise in der Spam-Mail Erkennung, bei Produktvorschlägen bei Einkäufen im Internet oder bei der Objekterkennung auf Bildern [73, S.185-204]. Da in Kapitel 5 auf die Hilfe von ML-Algorithmen zurückgegriffen wird, ist es erforderlich, dazu einen Überblick zum Stand der Technik zu geben. Da die Verwendung von ML in dieser Arbeit in Abschnitt 5.1.3 mithilfe der High Level Toolbox *Scikit-learn* für *Python* erfolgt, wird der Fokus auf die Vorstellung der zugrundeliegenden Konzepte und nicht auf die Beschreibung der mathematischen Implementierung gelegt.

ML-Algorithmen für Regressionsprobleme sind hauptsächlich im Bereich des Supervised Learning verortet. Eine partielle Hierarchiestruktur für die Einordnung in die Teilgebiete des ML wird in Abbildung 2.12 gezeigt. Das Supervised Learning zeichnet sich durch die Existenz eines Trainingsdatensatz mit gekennzeichneten Daten aus. Ein Trainingsdatensatz besteht aus einer Eingangsmatrix X_{train} der Größe $(n_{Beispiele}, n_{Merkmale})$ und einem Ergebnisvektor Y_{train} [74]. Die Anzahl der Merkmale wird auch als Dimensionalität des Datensatzes bezeichnet. Anhand der Trainingsdaten kann der Algorithmus den Zusammenhang zwischen den Merkmalen und dem jeweiligen Ergebnis erlernen. Dieser Lernprozess ist Voraussetzung zur Verwendung und zwischen den verschiedenen Algorithmen unterschiedlich. Geprüft wird der angelernte Algorithmus mithilfe von einem Testdatensatz X_{test} . Der Algorithmus nimmt auf Basis von X_{test} eine Prädiktion von \hat{Y}_{test} vor. Dabei geht es bei Regressionsalgorithmen um die Prädiktion von realen Zahlen und nicht um die Einordnung in eine Klasse, wie es bei den Klassifikationsalgorithmen der Fall ist. Ein Beispiel für die Anwendung von Regressionsalgorithmen ist die Prädiktion des Marktwerts eines Hauses basierend auf der Quadratmeterzahl, dem Baujahr und des Ortes. Mithilfe von Metriken, wie in Abschnitt 2.4.2 vorgestellt, kann durch den Abgleich der prädizierten Ausgangswerte \hat{Y}_{test} und den realen Ergebnissen Y_{test} die Güte des Algorithmus bewertet werden. Die folgende




Abbildung 2.12: Einordnung von Regression Algorithmen im Bereich der Artificial Intelligence

Vorstellung erklärt die Basiskonzepte einiger Regressionsalgorithmen.

k-Nearest Neighbor Algorithmus

Der k-Nearest Neighbor (KNN) Algorithmus ist von geringer Komplexität und benötigt kein tieferes mathematisches Konzept. Basierend auf dem Trainingsdatensatz werden bei der Prädiktion, die k -räumlich-nächsten Beispiele herangezogen und ihre jeweiligen Werte aus Y_{train} gemittelt. Für den Fall eines zweidimensionalen Datensatzes kann das Konzept für $k = 3$ durch Abbildung 2.13 visualisiert werden. Die mathematische Beschreibung der Mittlung wird in Gleichung 2.18 gegeben.




Abbildung 2.13: Diagramm zeigt einen Datensatz und visualisiert das Vorgehen des k-Nearest Neighbor Algorithmus. Grafik in Anlehnung an [73, S.39]

$$\hat{y}_i = \left(\sum_{i=1}^k y_i \right) / k \quad (2.18)$$

Der KNN Algorithmus ist aufgrund seiner Einfachheit ein robuster Algorithmus. Da abseits der Suche im bekannten Datensatz kein Lernvorgang stattfindet, wird der KNN Algorithmus als *fauler Algorithmus* bezeichnet [71, S.72]. Liegen die Trainingsdaten in hinreichender Auflösung vor, kann der Algorithmus präzise Ergebnisse liefern. Der Nachteil liegt in den hohen Speicheranforderungen bei großen Trainingsdatensätzen, weil der Datensatz während der Verwendung des Algorithmus permanent im Speicher gehalten werden muss [73, S.40]. Die Geschwindigkeit ist vergleichsweise langsam, da bei jeder Ausführung die Distanz zu allen Punkten berechnet werden muss und damit direkt abhängig von der Größe des Datensatzes ist.

Lineare Regression

Die lineare Regression ist ein Konzept aus der Statistik und der Prozess der Annäherung eines Datensatzes durch ein Polynom der Form wie in Gleichung 2.19.

$$y(x) = b_0 + \sum_{i=1}^d b_i x_i \quad (2.19)$$

Die Parameter b_0, \dots, b_n sind die zu ermittelnden Parameter durch die Regression. Die Komponenten x_i stehen für die jeweiligen Merkmale aus dem Eingangsvektor. Dabei kann x_i durch einen beliebigen Term ersetzt werden, der x_i enthält, wie beispielsweise $\log(x_i)$, um nichtlineare Zusammenhänge durch lineare Regression annähern zu können. Die Auswahl des passenden Terms für x_i hängt von den bekannten Zusammenhängen des Merkmals mit dem Ausgang ab. In Abbildung 2.14 wurde für den eindimensionalen Datensatz X_{train} ein quadratischer Komponententerm gewählt. Die Regression zur Annäherung der Parameter b_0, \dots, b_n geschieht




Abbildung 2.14: Diagramm zeigt einen beispielhaften Trainingsdatensatz und das angenäherte Polynom durch die lineare Regression

durch die Minimierung der Summe des quadrierten Fehlers zwischen Eingangswerten und dem angenäherten Polynom. Die Methode wird Kleinste-Quadrate-Methode genannt [75, S.35] und kann durch Gleichung 2.20 beschrieben werden. Dabei steht b_{lr} für den Vektor der optimalen Parameter b_0, \dots, b_n und p für die Anzahl an Beispielen im Trainingsdatensatz.

$$b_{lr} = \arg \min \left(\sum_{i=1}^p \left(y_i - \sum_{j=1}^n (b_j x_{ij}) + b_0 \right)^2 \right) \quad (2.20)$$

Neuronale Netzwerke

Neuronale Netze sind heutzutage im Bereich des Machine Learning weit verbreitet. Das Konzept ist stark durch die Arbeitsweise des Gehirns inspiriert [71, S.103]. Das Kernelement eines neuronalen Netzes, das Neuron (einfaches Perceptron), wurde zuerst von *Rosenblatt* vorgestellt [76]. Die Anordnung von Perzeptronen in mehreren Schichten führte zur Entwicklung der Artificial Neural Network (ANN), auch Multi Layer Perceptron (MLP) genannt, die für die spätere Verwendung in dieser Arbeit im Folgenden vorgestellt werden. Die Beliebtheit der Neuronalen Netze für ML-Anwendungen, wie die Sprach- oder Bilderkennung, führte zur Entwicklung von weiteren Ausprägungen der Neuronalen Netze, wie Deep Neuronale Network (DNN), Recurrent Neuronale Network (RNN) oder Convolutional Neuronale Network (CNN). Die Datenverarbeitung

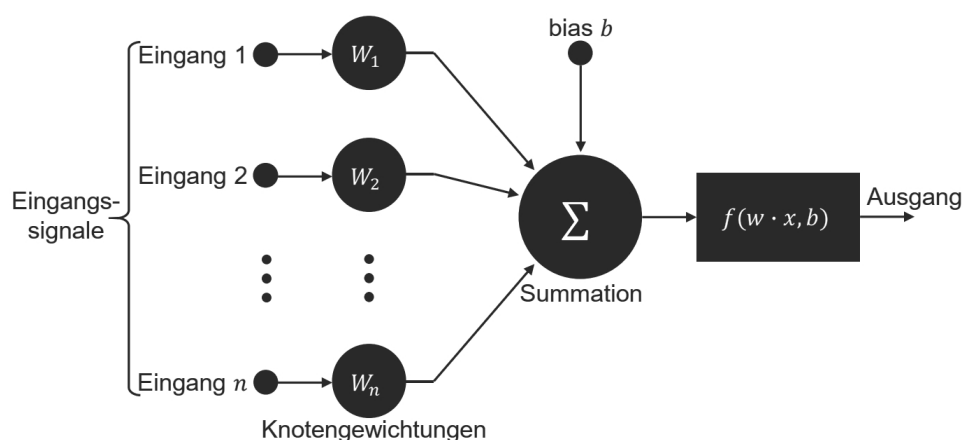


Abbildung 2.15: Aufbau eines Neuron. [77, S.14] in Anlehnung an [72, S.36]

innerhalb eines Neuron läuft nach dem folgenden Schema ab und wird in Abbildung 2.15 dargestellt:

1. Der n-dimensionale Eingangsvektor besteht aus den Eingangsmerkmalen $X = [x_1, x_2, \dots, x_n]$.
2. Jede Eingangsgröße wird mit einem Gewichtungsfaktor w_n multipliziert. Diese Gewichtungsfaktoren können als Gewichtungsvektor $W = [w_1, w_2, \dots, w_n]$ notiert werden.
3. Die gewichteten Eingangsgrößen werden summiert. In Matrixschreibweise kann das durch $X^T W$ dargestellt werden.
4. Der konstante Wert b (Bias) wird zu $X^T W$ addiert. Daraus ergibt sich der Eingangswert für die Aktivierungsfunktion.
5. Durch die Aktivierungsfunktion f erfolgt die Berechnung des Ausgangswert des Neurons. Die Art der Aktivierungsfunktion bestimmt, wie das Problem durch das Neuronale Netz gelernt wird. Soll das Neuronale Netz einen nichtlinearen Zusammenhang erlernen, ist die Verwendung einer nichtlinearen Aktivierungsfunktion notwendig. Häufig verwendete Funktionen sind sigmoid, tanh oder relu [78, S.] und werden in Abbildung 2.16 dargestellt. Zum Vergleich wird die lineare Aktivierungsfunktion identity ebenfalls gezeigt.

Alle Berechnungsschritte innerhalb des Neurons zur Ermittlung des Ausgangs y werden zusammengefasst beschrieben durch Gleichung 2.21.

$$y = f(X^T W + b) \quad (2.21)$$

Ein MLP besteht aus einer Eingangs- und Ausgangsschicht sowie dazwischengeschalteten




Abbildung 2.16: Häufig verwendete Aktivierungsfunktionen. identity: $y = x$, sigmoid: $y = \frac{1}{1+e^{-x}}$, tanh: $y = \tanh(x)$, relu: $y = \max(0, x)$

Neuronen, angeordnet in n Anzahl Schichten (Hidden Layer [75, S.226]) mit m Neuronen parallel. In Abbildung 2.17 wird der Aufbau beispielhaft dargestellt. Es gibt bis heute noch keine Theorie darüber, wie viele Hidden Layer für eine bestimmte Anwendung optimal sind [73, S.48]. Die Breite m kann in jeder Schicht unterschiedlich sein [73, S.44]. Eine Besonderheit des MLP ist die Vollvernetzung und die Feed-Forward Arbeitsweise. Der Ausgang jedes Neurons ist mit jedem Eingang der Neuronen des nächsten Layers verknüpft. Die Berechnung des Ergebnisses erfolgt streng in Vorwärtsrichtung des MLP von Eingangsschicht zu Ausgangsschicht [73, S.44]. Ein




Abbildung 2.17: Aufbau eines Multi Layer Perceptron mit drei Hidden Layer aus jeweils drei Neuronen [77, S.14] in Anlehnung an [73, S.45]

MLP kann mithilfe eines Trainingsdatensatz, bestehend aus den Eingangswerten X_{train} und den bekannten Ausgangswerten Y_{train} , angeleitet werden. Mithilfe eines Optimierungsalgorithmus wird iterativ der berechnete Ausgang durch das MLP mit den bekannten Ausgangswerten abgeglichen und zur Reduzierung des Fehlers die Gewichts- und Bias-Parameter angepasst. Dazu wird die Ableitung der Kostenfunktion gebildet, um die Richtung für die Anpassung der Parameter zu erhalten [71, S.114 ff.]. Die Auswahl des Optimierungsalgorithmus hat Einfluss auf die Lerngeschwindigkeit und die erreichbare Güte des Netzes. Als Standard hat sich der Adams-Algorithmus etabliert, der in dieser Arbeit verwendet wird [79]. Das Training erfolgt in

Epochen. Der Abschluss einer Epoche bedeutet, dass jeder Eintrag des Testdatensatz durch den Optimierungsalgorithmus einmal verarbeitet und die Gewichts- und Bias-Parameter angepasst wurden. Für ein bestmögliches Training des Neuronales Netz ist die Auswahl der passenden Hyperparameter die zentrale Aufgabe, um eine gute Anpassung zu erreichen. Mögliche Hyperparameter sind abhängig von der gewählten Implementierung und umfassen [73, S.50]:

- Anzahl der Hidden Layer
- Anzahl der Neuronen je Layer
- Anzahl der Trainingsepochen
- Auswahl der Aktivierungsfunktion
- Initialisierung der Gewichte
- Auswahl des Optimierungsalgorithmus
- Verwendung von Regularisierungsmaßnahmen

Durch den Einsatz von Regularisierungsmaßnahmen kann einer Überanpassung entgegen gewirkt werden. [73, S.50-51]. Durch ein sehr großes Netz oder sehr intensives Training kann ein Neuronales Netz dazu neigen, übermäßig an die Trainingsdaten angepasst zu werden. Dabei verliert das Netz seine Fähigkeit zu generalisieren und es leidet die Leistungsfähigkeit bei ungesehenen Daten. Der Schlüssel liegt darin, ein gutes Gleichgewicht zwischen der allgemeinen Anpassung des Netzwerks an die Trainingsdaten und der Vermeidung des Lernens der Varianz in den Daten zu finden. Der Kompromiss wird Bias-Variance-Trade-off genannt. Der Unterschied zwischen Unteranpassung und Überanpassung wird in Abbildung 2.18 dargestellt.




Abbildung 2.18: Vergleich zwischen Überanpassung und Unteranpassung im Trainingsprozess [80]

2.4.2 Fehler-Metriken

Fehler-Metriken finden Verwendung, um die Güte eines ML-Algorithmus mithilfe eines Fehlerwertes auszudrücken. Damit können sie in einer Optimierungsfunktion verwendet werden, um den Fehler-Wert systematisch zu minimieren. Die vorgestellten Metriken sind für numerische Werte geeignet und werden häufig bei Regressionsalgorithmen verwendet.

Mean Absolute Error

Der Mean Absolute Error (MAE) wird in Gleichung 2.22 definiert. \hat{y}_i steht für den durch den Algorithmus prädizierten Wert und y_i für den bekannten, wahren Wert.

$$MAE = \frac{\sum_{i=1}^n |\hat{y}_i - y_i|}{n} \quad (2.22)$$

Für die Berechnung des MAE wird der Betrag verwendet, um zu verhindern, dass sich positive und negative Fehler gegenseitig auslöschen [73, S.170]. Es ist darüber hinaus möglich, den Einzelfehler wie in Gleichung 2.23 gezeigt, mit einem Wert w_i zu gewichten. Damit können anhand des Gewichtungswertes einzelne Beispieldaten einen höheren Einfluss auf den Fehlerwert nehmen.

$$MAE_w = \frac{\sum_{i=1}^n |\hat{y}_i - y_i| w_i}{n} \quad (2.23)$$

Mean Squared Error

Anstatt des absoluten Fehlers wird der Fehler für die Berechnung des Mean Squared Error (MSE) quadriert, um die Auslöschung von positiven und negativen Fehlern zu unterbinden. Der MSE ist gegenüber dem MAE aufgrund der Quadrierung sensitiver auf einzelne Ausreißer. Die Berechnungsvorschrift ist gegeben in Gleichung 2.24 für den MSE und in Gleichung 2.25 für den gewichteten MSE. Durch das Ziehen der Wurzel ergibt sich der Root Mean Squared Error (RMSE), der nicht mit dem MAE gleichzusetzen ist.

$$MSE = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n} \quad (2.24)$$

$$MSE_w = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2 w_i}{n} \quad (2.25)$$

R² Wert

Der R² Wert wird auch *Bestimmtheitsmaß* genannt [74]. Er ist das Maß dafür, wie stark die beobachtbare Varianz durch die Varianz des zweiten Datensatzes erklärt wird. Der bestmögliche Wert für den R² Wert ist 1. In diesem Fall kann die Varianz zu 100% nachgebildet werden. Wenn der Algorithmus unabhängig von den Eingangsmerkmalen einen konstanten Wert vorhersagt, liegt der R² Wert bei Null. Ein negativer R² Wert ist ebenfalls möglich [74]. Der Vorteil gegenüber dem MSE und dem MAE liegt in der Normierung des R² Werts. Die Formel für den R² Wert wird in Gleichung 2.26 gegeben. \bar{y}_i steht für das arithmetische Mittel des Ergebnisvektors y_i . Aufgrund des identischen Zählerterms im Vergleich zur Gleichung 2.24 wird bei der Verwendung von MSE und R² Wert als Metrik einer Optimierungsfunktion das Minimum an derselben Stelle gefunden.

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (2.26)$$

3 Methoden A: Erstellung von Giermomentdiagrammen

Die ursprünglich von *Milliken* skizzierte Methodik zur Generierung von Giermomentdiagrammen basiert auf einem physikalischen Fahrzeugmodell und erfordert einen aufwendigen Prüfstand. Da ein detailliertes, virtuelles Fahrzeugmodell heute Stand der Technik in der Fahrzeugentwicklung ist, wird die Methodik als virtueller Prüfstand umgesetzt. *Kang et. al.* [15] beschreiben die grundlegende Implementierung der MMM mit Hilfe einer Fahrdynamiksimulation. Hierauf wird in diesem Kapitel aufgebaut. In Unterkapitel 3.1 werden die Anforderungen und das Ziel der Anwendung aufgezeigt. Unterkapitel 3.2 umfasst die Beschreibung des Vorgehens bei der Implementierung der Anwendung.

3.1 Zielsetzung

Die Zielsetzung für die Anwendung zur Erstellung von Giermomentdiagrammen wurde nach der Literaturrecherche erstellt und bezieht Erkenntnisse anderer Autoren bereits mit ein. Als Ziele wurden folgende Anforderungen abgeleitet:

1. Die Anwendung nutzt die bestehenden Fahrdynamikmodelle und ist um diese herum aufgebaut. Die Verwendung der vorhandenen Fahrdynamikmodelle als Black-Box erleichtert die Anpassung der Anwendung an ein anderes Projekt und fördert die Open-Source Verwendung.
2. Die Anwendung gibt das universelle Giermomentdiagramm mit konstanter Geschwindigkeit aus. Im Gegensatz zu den Giermomentdiagrammen mit konstantem Radius ist es vielseitiger und bedient den Anwendungsfall des Rundstrecken- und Ovalrennsports. Die Anwendung kann Fahrsituationen in stationärer Kurvenfahrt und kombinierte Beschleunigungs- und Bremsszenarien simulieren.
3. Simulationen für das Roborace- und das Indy Lights-Fahrzeug sollen möglich sein. Wenn es strecken- oder fahrzeugspezifische Details gibt, die durch die bestehende Fahrdynamikmodellierung nicht abgebildet werden, wird das Modell erweitert. Notwendige Erweiterungen sind eine zwischen Vorder- und Hinterachse einstellbare Bremsbalance und eine parametrierbare Antriebsmomentenverteilung, da die bestehenden Fahrdynamikmodelle jeweils die Antriebsmomente und Bremsdrücke als Eingang erwarten. Um die Ovalstrecken des Indy-Lights-Fahrzeug abzubilden, ist die Berücksichtigung von Fahrbahnneigung eine weitere, erforderliche Erweiterung.
4. Das Postprocessing erzeugt aus den Simulationsergebnissen das Giermomentdiagramm für jede Kombination von Geschwindigkeit und Längsbeschleunigung. Zu-

sätzlich werden Diagramme zur Bewertung von Stabilitäts- und Kontroll-Eigenschaften erzeugt. Um verschiedene Simulationsläufe mit unterschiedlichen Parametersätzen vergleichen zu können, wird durch die Anwendung automatisiert eine Berechnung von KPIs vorgenommen.

5. Die Anwendung wird in Matlab und Python aufgebaut. Matlab ist weit verbreitet und einfach zu benutzen. Es sind vielseitige Toolboxes verfügbar und mit Simulink eine Schnittstelle zum grafischen Programmieren. Python ist eine High-Level Open-Source Programmiersprache mit vielen Erweiterungen für Datenverarbeitung und Machine Learning. Python besitzt gegenüber Matlab den Vorteil, dass es kostenlos ist und sich daher für Open-Source Software eignet. Da zu Beginn der Arbeit die bestehenden Fahndynamikmodelle nur in Matlab verfügbar sind, wird die Anwendung zuerst in Matlab entwickelt und anschließend nach Python übertragen. Die Python Version wird als Open-Source-Package in GitHub veröffentlicht

3.2 Aufbau der Giermomentdiagramm-Anwendung

Abschnitt 3.2.1 beschreibt das Modelldesign und die Funktionsweise der einzelnen Blöcke der Implementierung. Eine Beschreibung des Simulationsablaufs wird ebenfalls gegeben. In Abschnitt 3.2.2 wird der Simulationsablauf beschrieben. Abschnitt 3.2.3 folgt mit einer Darstellung der Funktionsweise des Postprocessings, um Diagramme zu erstellen und KPIs zu berechnen.

3.2.1 Modelldesign

Die Aufgabe des Modells ist es, das virtuelle Fahrzeug für eine gegebene Kombination von Geschwindigkeit v , Längsbeschleunigung a_x , Schwimmwinkel β und Lenkwinkel δ zu einem stabilen Zustand zu konvergieren und die resultierende Querbeschleunigung a_y und Giermoment M_z zu ermitteln. Es orientiert sich von der Idee an dem skizzierten Prüfstand von *Milliken* aus Abbildung 2.4. Die Seilverbindungen an das Fahrzeug werden in der Simulation durch externe Kräfte und Momente umgesetzt, die direkt auf den Schwerpunkt wirken. So wird sichergestellt, dass das Fahrzeug weiter frei rollen, nicken und sich in vertikaler Richtung bewegen kann.

Die Seilverbindungen in Abbildung 2.4 stützen die resultierenden Längs- und Querkräfte des Fahrzeugs sowie das Giermoment ab. Im Fall der Umsetzung in der Simulation ist das Abstützen in Querrichtung nicht notwendig, sodass sich das Fahrzeug auf der virtuellen Fahrfläche in einem Kreis bewegt. Eine Abstützung des Fahrzeugs in Querrichtung, würde zu einer Fehlberechnung der Schräglaufwinkel führen, weil dadurch die Gierrate bei $\dot{\psi} = 0$ konstant gehalten wird. Dass die Schräglaufwinkel von der Gierrate abhängig sind, ist durch Gleichung 2.10 und Gleichung 2.11 aus dem ESM zu erkennen. An dieser Stelle besitzt die Umsetzung in der Simulation einen Vorteil gegenüber dem durch *Milliken* vorgeschlagenen Prüfstand aus Abbildung 2.4. Eine Berücksichtigung des Einflusses der Gierrate ist aufgrund der örtlichen Fixierung auf der Laufrolle nicht möglich.

Die Abstützung der Längskräfte ist für Szenarien mit Längsbeschleunigung $a_x \neq 0 \text{ m/s}^2$ notwendig, da über die Laufzeit der Simulation bis zur Konvergenz die Geschwindigkeit konstant gehalten wird. So können sich trotz konstanter Geschwindigkeit die entsprechenden Radlasten und Radmomente einer Fahrsituation mit Längsbeschleunigung einstellen.

Gezeigt wird die Modellstruktur in Abbildung 3.1 als schematisches Blockdiagramm, angelehnt an die Implementierung in Matlab Simulink. Für die Python Implementierung ist das Modell in objektorientiertem Code geschrieben. Da die Blockdarstellung eine bessere Verständlichkeit bietet, wird sie für die Dokumentation bevorzugt. Von der Darstellung in Blockdiagrammen abgesehen, bezieht sich der Methodik-Teil auf die Vorstellung der Python-Implementierung, da diese als Open-Source-Version veröffentlicht wird.

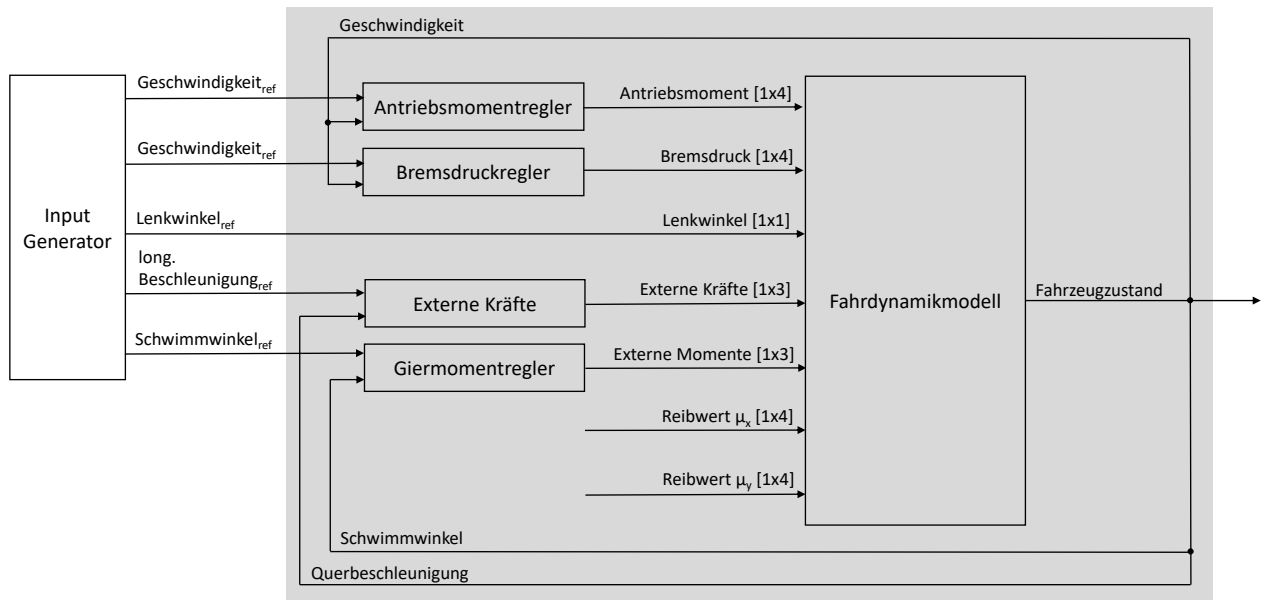


Abbildung 3.1: Blockschaubild Milliken Moment Method. Implementierung auf Basis eines bestehenden Fahrtdynamikmodell. Abbildung zeigt die Einbindung der vorgelagerten Regler.

Wie in Abbildung 3.1 zu sehen, gibt es neben dem Fahrtdynamikmodell fünf weitere Blöcke:

- Input Generator
- Antriebsmomentregler
- Bremsdruckregler
- Externe Kräfte
- Giermomentregler

Eine Übersicht über die Funktionen der Blöcke wird im Folgenden gegeben.

Input Generator

Der Input Generator erstellt eine Eingangsmatrix für die Simulation mit den Merkmalen Geschwindigkeit v , Längsbeschleunigung a_x , Schwimmwinkel β und Lenkwinkel δ . Jede Zeile entspricht den Eingangsmerkmalen für eine Lösungsschleife der Simulation. In Abhängigkeit der vorgegebenen Wertebereiche für jedes Merkmal wird durch den Input Generator eine Matrix mit $n_v * n_{a_x} * n_\beta * n_\delta$ Reihen und vier Spalten aufgestellt. Diese Eingangsmatrix ist die Warteschlange der Simulation und enthält alle möglichen Kombinationen der Merkmale. Eine solche Eingangsmatrix ist die Grundlage für eine Parallelisierung der Simulation, die in von Abschnitt 3.2.2 beschrieben wird. Die Verwendung der vier Merkmale in der Simulation wird in Tabelle 3.1 beschrieben.

Tabelle 3.1: Verwendung der Eingangsmerkmale in der Simulation

Merkmal	Verwendung in der Simulation
v	Sollgröße für den Antriebsmoment- und Bremsdruckregler
a_x	Eingangsgröße zu Berechnung der statischen, externen Longitudinalkraft
β	Sollgröße für den Giermomentregler
δ	Statische Eingangsgröße für das Fahrdynamikmodell

Antriebsmomentregler

Das Fahrdynamikmodell erwartet ein Eingangsarray der Größe [1x4] mit den Antriebsmomenten in Nm für jedes Rad. Die Radmomente werden direkt vorgegeben, eine Modellierung des Antriebsstrangs erfolgt nicht. Über den Verlauf einer Simulationsschleife bis zur Konvergenz der Ausgangsgrößen ist es die Aufgabe des Antriebsmomentreglers, die Fahrzeuggeschwindigkeit auf die Sollgeschwindigkeit v_{ref} einzuregeln. Der Antriebsmomentregler ist als PI Regler implementiert und wird beschrieben durch Gleichung 3.1 und Gleichung 3.2.

$$M_{r,ges}(t) = K_P e_v(t) + K_I \int_0^t e_v(\tau) d\tau \quad (3.1)$$

$$e_v(t) = v_{ref}(t) - v(t) \quad (3.2)$$

Ohne weitere Parametrierung wird das Antriebsmoment zwischen den zwei Rädern der Hinterachse gleichverteilt. Damit verhält sich der Antriebsmomentregler wie ein offenes Differential [29, S.735]. Das Roborace Fahrzeug verfügt über ein Torque Vectoring (TV) System, das das Antriebsmoment zwischen den angetriebenen Rädern der Hinterachse frei verteilen kann. Dadurch kann ein zusätzliches Giermoment nach Gleichung 3.3 erzeugt werden. Das erzeugbare Giermoment ist abhängig von Antriebsmomentdifferenz $M_{r,RR} - M_{r,RL}$, dem effektiven Reifenradius der angetriebenen Achse $r_{RL,RR}$ und der Spurweite TW . Eine Überschlagsrechnung für die Parameter der Roborace Fahrzeugs ergibt, basierend auf dem Maximaldrehmoment der Motoren und Gleichung 3.3, ein mögliches Giermoment durch TV von $M_{z,TV,max} \approx 10 \text{ kNm}$. Aus dem Giermomentdiagramm lässt sich für das Roborace Fahrzeug, abhängig von er Geschwindigkeit, ein maximales Giermoment von $M_{z,max} = 20 - 30 \text{ kNm}$ ermitteln. Daher werden die Giermomente aus Reifenlängskraftdifferenzen des TV als relevant für das Ergebnis angesehen.

$$M_{z,TV} = \frac{M_{r,RR} - M_{r,RL}}{r_{RL,RR}} \frac{TW}{2} \quad (3.3)$$

Der Aufbau des TV Systems ist nicht bekannt und wird durch den Eigentümer unter Verschluss gehalten. Aufgezeichnete Messdaten des Roborace Fahrzeugs enthalten jedoch die Antriebsmomente als Messwerte und ermöglichen ein Rückwärts-Entwicklung des TV. Mithilfe einer Überprüfung der Korrelation des Giermoments durch TV mit weiteren Sensorsignalen, können mögliche Eingangssignale für das TV System gefunden werden. Die Quereschleunigung a_y zeigt die höchste Korrelation. Eine Annäherung an das Verhalten des TV Systems kann daher durch Gleichung 3.4 gefunden werden. Abbildung 3.2 zeigt das Giermoment basierend auf den Messdaten und Gleichung 3.3, ebenso wie das nach Gleichung 3.4 berechnete Giermoment mit einem empirisch ermittelten Faktor von $f_{TV} = 130$. Die beobachtbare Übereinstimmung ist über einen weiten Bereich von Fahrzeugmanövern ausreichend, sodass Gleichung 3.4 für die Berechnung der Antriebsmomentenverteilung verwendet wird.

$$M_{z,TV,sim} = f_{TV} a_y \quad (3.4)$$




Abbildung 3.2: Vergleich des gemessenen Giermoments aus dem TV-System des Devbot mit der Implementierung in der Simulation

Bremsdruckregler

Für Szenarien mit negativer longitudinaler Beschleunigung a_x ist der Antriebsmomentregler inaktiv und der Bremsdruckregler sorgt für eine konstante Fahrzeuggeschwindigkeit. Das Fahrdynamikmodell erwartet ein Eingangsarray der Größe [1x4] mit den Bremsdrücken in Pa für jedes Rad. Der Bremsdruckregler ist ebenfalls durch einen PI-Regler nach Gleichung 3.5 implementiert. Der P-Anteil sorgt für eine schnelle Reaktion auf Regelabweichungen und der I-Anteil sorgt dafür, dass die bei einem reinen P-Regler verbleibende Regelabweichung kompensiert wird. Um ein Aufziehen des Integralteil zu verhindern wird das Fahrzeug bereits mit der Sollgeschwindigkeit initialisiert.

$$p_B(t) = K_P e_v(t) + K_I \int_0^t e_v(\tau) d\tau \quad (3.5)$$

Die Verteilung des Bremsdruck auf den vorderen und hinteren Bremskreislauf wird nach dem Ausgang des PI-Reglers durch einen Parameter vorgenommen und nach Gleichung 3.6 und Gleichung 3.7 berechnet.

$$p_{B,FL,FR} = p_B BB \quad (3.6)$$

$$p_{B,RL,RR} = p_B (1 - BB) \quad (3.7)$$

Externe Kräfte

Das Fahrdynamikmodell erwartet ein Eingangsarray der Größe [1x3] mit den auf den Fahrzeugschwerpunkt wirkenden, externen Kräften in alle drei Raumrichtungen in N. Der Block für die

externen Kräfte beinhaltet zwei Funktionen. Die erste Funktion berechnet die Massenträgheitskraft, um eine longitudinale Beschleunigung a_x zu simulieren, die durch den Antriebsmomentregler oder Bremsdruckregler ausgeglichen wird. Diese F_x Komponente wird berechnet durch Gleichung 3.8.

$$F_x = -m a_{x,ref} \quad (3.8)$$

Die zweite Funktion im Block der externe Kräfte modelliert den Neigungswinkel der Fahrbahn und den damit verbundenen Einfluss der auf das Fahrzeug wirkenden Kräfte. Das Fahrtdynamikmodell basiert auf der Annahme, dass der Vektor der Gewichtskraft und die Z-Achse des Fahrzeugs parallel verlaufen. Im Fall einer geneigten Fahrbahn ist diese Annahme nicht mehr erfüllt, wie durch Abbildung 3.3 ersichtlich. In Abhängigkeit der Querbewegung a_y und dem Neigungswinkel γ werden die Komponenten ΔF_y und ΔF_z nach Gleichung 3.9 und Gleichung 3.10 berechnet. Da die Gewichtskraft bereits im Fahrtdynamikmodell berücksichtigt wird, ergibt sich die Komponente ΔF_z als Differenz zwischen der Gewichtskraft und dem Gewichtsvektor der Fahrzeughochachse.

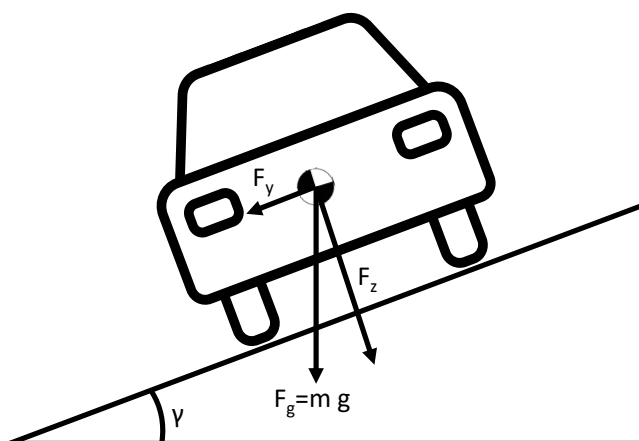


Abbildung 3.3: Kräfte am Fahrzeug in einer Kurve mit Fahrbahnneigung

$$\Delta F_y = -(1 - \cos(\gamma)) m a_y + \sin(-\gamma) m g \quad (3.9)$$

$$\Delta F_z = \sin(-\gamma) m a_y + (1 - \cos(\gamma)) m g \quad (3.10)$$

Giermomentregler

Das Fahrtdynamikmodell erwartet ein Eingangsarray der Größe [1x3] mit den externen Momenten um alle drei Raumachsen in Nm. Die Aufgabe des Giermomentreglers ist es, den Zielschwimmwinkel β_{ref} durch ein externes Giermoment um die Hochachse M_z einzuregeln. Die Ausgänge für M_x und M_y werden dafür nicht benötigt und sind auf 0 gesetzt. Aufgrund des dynamischen Systemverhaltens bei der Regelung auf den Schwimmwinkel, hat sich der Einsatz eines PID-Reglers als erfolgreich herausgestellt. Durch den zusätzlichen D-Anteil kann die Neigung des Reglers zum unkontrollierten Aufschwingen unterbunden werden. Der Regler

wird durch Gleichung 3.11 und Gleichung 3.12 beschrieben.

$$M_z(t) = K_P e_\beta(t) + K_I \int_0^t e_\beta(\tau) d\tau + K_D \frac{de_\beta(t)}{dt} \quad (3.11)$$

$$e_\beta(t) = \beta_{ref}(t) - \beta(t) \quad (3.12)$$

3.2.2 Simulationsablauf

Für das Lösen eines Szenarios, das einer Reihe der Eingangsmatrix entspricht, geht die Simulation wie folgt vor:

1. Initialisieren des Fahrzeugs in Geradeausfahrt mit Fahrzeuggeschwindigkeit v_{ref} und Raddrehzahlen ω_{ref} .
2. Die simulierte Trägheitskraft F_x wird ab Beginn der Simulation auf 100% des Werts aus Gleichung 3.8 gesetzt. Die Referenzwerte für β_{ref} und δ_{ref} werden durch ein PT1-Glied gedämpft, wie in Abbildung 3.4 dargestellt wird. Dadurch wird die Gefahr minimiert, dass das System aufgrund eines großen Impulses oder eines Aufziehens des I-Anteils des Giermomentreglers zu schwingen beginnt.
3. Die Simulationszeit ist auf 10s festgelegt. Die gewählte Dauer ist ein guter Kompromiss aus ausreichender Zeit für die Konvergierung des Fahrzustands und Minimierung des Rechenzeitaufwands.
4. Die Werte der Querbearbeitung a_y und des Giermoments M_z werden für die letzte Sekunde gemittelt und als Ergebnis der Simulation ausgegeben.
5. Als Referenzwert für die Konvergenz der Simulation wird die Standardabweichung der Querbearbeitung a_y als Ergebnis gespeichert. Sind die Referenzwerte noch nicht erreicht oder haben sich die Regler aufgeschwungen, so kann dies an der Standardabweichung von a_y erkannt werden.




Abbildung 3.4: Zeitverlauf der Referenzwerte mit PT1 Verzögerungsglied für β und δ in der Simulation

Der Simulationsablauf kann durch Parallelisierung beschleunigt ausgeführt werden. Dazu wird das *Concurrent Futures Package* für Python verwendet. *Concurrent Futures* ist eine High-Level Schnittstelle zur asynchronen Ausführung von Funktionen auf mehreren Threads mithilfe des *Process Pool Executors* [81]. Die Beschleunigung der Simulation durch das *Concurrent Futures Package* ist durch die Anzahl der Threads des verwendeten Prozessors beschränkt. Bei der Ausführung startet der *Process Pool Executor* mehrere Prozessinstanzen mit einer Kopie des Modells. Ist ein Prozess frei, wird er mit der nächsten Zeile aus der Eingangsmatrix versorgt und die Simulation ausgeführt. Ist die Simulation auf der Prozessinstanz abgeschlossen, werden die Ergebnisse in die Ausgangsmatrix geschrieben. Dabei ist der Zeilenindex in Eingangs- und Ausgangsmatrix unabhängig von der Simulationsreihenfolge identisch. Wenn ein Prozess länger läuft als ein anderer, kommt es deshalb nicht zu einer Vermischung in der Reihenfolge der Ausgangsmatrix. Das asynchrone Abarbeiten der Eingangsmatrix durch die Prozessinstanzen wird in Abbildung 3.5 visualisiert.




Abbildung 3.5: Parallelisierte Simulation mithilfe des *Process Pool Executors*. Abbildung zeigt das Vorgehen bei asynchroner Abarbeitung der Eingangsmatrix. Die Zuordnung der Ausgangswerte zu den Eingangswerten erfolgt über den Zeilenindex.

3.2.3 Postprocessing

Das Postprocessing Modul übernimmt die Aufbereitung der Simulationsdaten und Ableitung der KPIs, sowie die automatisierte Erstellung von Diagrammen. Im ersten Schritt wird die Ausgangsmatrix der Simulation in zwei 4D-Arrays für die Querbeschleunigung a_y und das Giermoment M_z umgewandelt. Dadurch ergibt sich der Vorteil das die Ergebnisse durch Indizierung einfach aufzurufen sind. Mit Hilfe der angepassten Datenstruktur können die drei charakteristischen Punkte im Giermomentdiagramm durch einen eigenentwickelten Algorithmus gefunden werden. Diese sind wie im Abbildung 2.7 bereits gezeigt:

1. Die Geradeausfahrt, im folgenden mit **straight** bezeichnet.
2. Der Punkt der maximalen Querbeschleunigung, im folgenden mit **lim** bezeichnet.
3. Der Punkt der maximalen Querbeschleunigung im stationären Fahrzustand mit Giermoment. $M_z = 0 Nm$, im folgenden mit **trim** bezeichnet.

Für die aufgeführten Punkte erfolgt die Ableitung der in Tabelle 3.2 beschriebenen KPI.

Tabelle 3.2: Berechnete KPI im Postprocessing

Bezeichnung	Einheit	Beschreibung	Anwendung
a_y	m/s^2	Querbeschleunigung	lim, trim
M_z	Nm	Giermoment	trim
$M_{z,max}$	Nm	maximales Giermoment	
β	deg	Schwimmwinkel	lim, trim
δ	deg	Lenkwinkel	lim, trim
Stabilitätsmoment	Nm/deg	Giermomentänderung über Schwimmwinkeländerung	straight, trim
Kontrollmoment	Nm/deg	Giermomentänderung über Lenkwinkeländerung	straight

Die Berechnung der KPI für Stabilität und Kontrolle im Punkt *lim* und Kontrolle im Punkt *trim* entfällt aufgrund der Unstetigkeit der β - und δ -Isolinien und der daraus resultierenden Undifferenzierbarkeit. Ein Vergleich von Stabilität und Kontrolle in der Geradeausfahrt ist bei Parametervariationen bereits ein guter Indikator für allgemeine Tendenzen über den gesamten Manöverraum.

Des Weiteren werden durch das Postprocessing die automatisierte Erstellung einer Reihe von Diagrammen übernommen. Üblicherweise wird für jeden Diagrammtyp und für jede Kombination von Längsbeschleunigung a_x und Geschwindigkeit v ein Diagramm erstellt. Die Auswahl der Diagramme umfasst neben dem Giermomentdiagramm, das 3D Giermomentdiagramm, sowie die Stabilitäts- und Kontroll-Contour-Diagramme auf die Unterkapitel 4.3 genauer eingegangen wird.

Die Ableitung der Giermomentendiagramme ist durch die Umwandlung der Datenstruktur in 4D-Arrays problemlos möglich. Werden die Vektoren mit konstantem Lenk- und Schwimmwinkel als Spalten- und Zeilenvektoren indiziert und nacheinander geplottet entsteht ein Giermomentdiagramm wie in Abbildung 3.6 gezeigt.

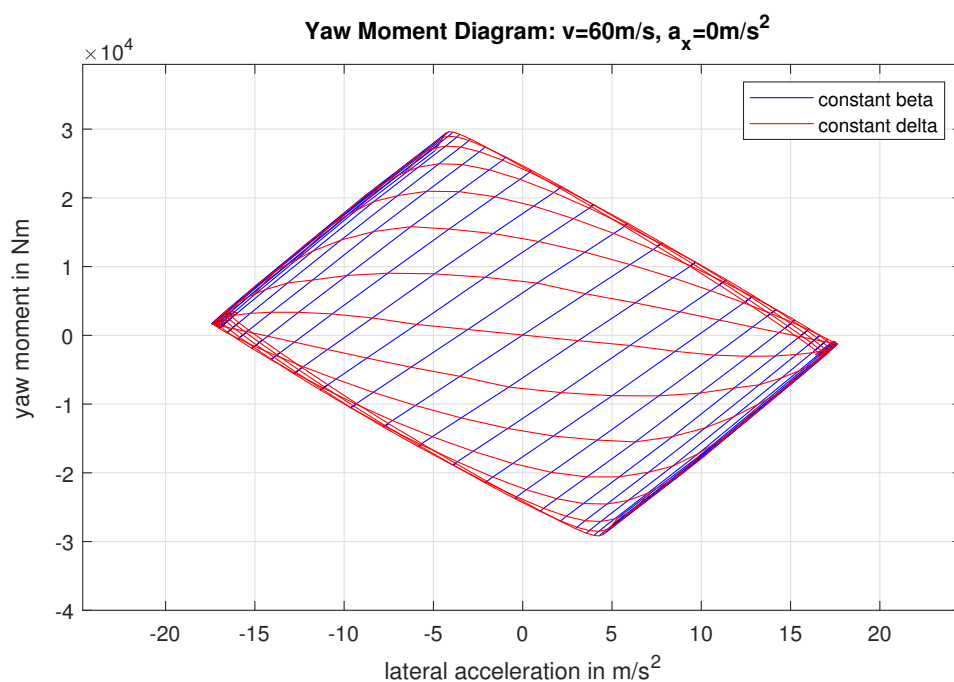


Abbildung 3.6: Beispielhaftes Giermomentdiagramm auf Basis des nichtlinearen Zweispurmodell, für die Geschwindigkeit $v = 60 m/s$ und Längsbeschleunigung $a_x = 0 m/s^2$

3 Methoden A: Erstellung von Giermomentdiagrammen

Zur besseren Übersichtlichkeit werden die Linien des Diagramms beschnitten. Ein Algorithmus durchläuft die Zeilen- und Spaltenarrays und erzeugt ein boolesches 4D Array, das bei einem Vorzeichenwechsel der Ableitung der Querbeschleunigung die Linie an der Stelle beendet. Dieses boolesche Array wird bei der Diagrammerstellung zur Beschneidung der Linien benutzt. Als Ergebnis werden die Fahrsituationen, bei denen die Reifen oberhalb ihres Querkraftmaximums betrieben werden, im Diagramm ausgeblendet. Der Unterschied wird in Abbildung 3.7 ersichtlich.

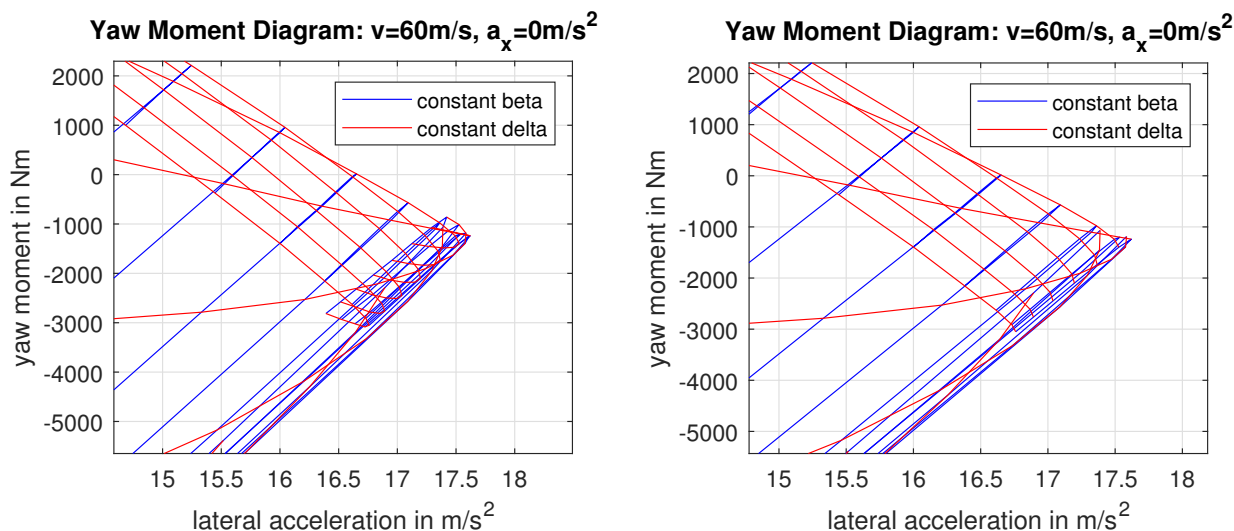


Abbildung 3.7: Bereinigung der Giermomentdiagramme zur Verbesserung der Übersichtlichkeit. Links: vor Bereinigung. Rechts: nach Bereinigung

Aus den Giermomentdiagrammen wird ein weiteres Diagramm abgeleitet, um den Einfluss der Geschwindigkeit aufzuzeigen. Die Umriss der Diagramme werden für jede Geschwindigkeit in ein neues Diagramm überführt. Durch die Darstellung kann ein schneller Überblick über die Veränderung der Stabilität im Grenzbereich und der maximalen Querbeschleunigung in Abhängigkeit der Geschwindigkeit gewonnen werden. Ein Beispiel dazu ist durch Abbildung 3.8 gegeben.

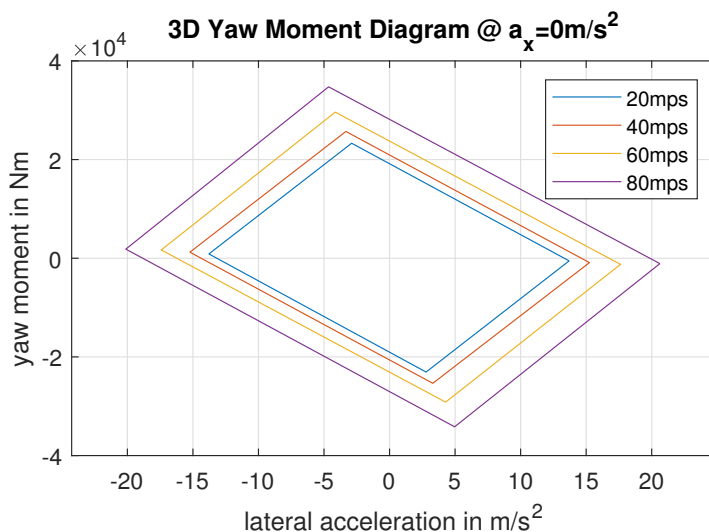


Abbildung 3.8: Überlagerung der Umrandung von Giermomentdiagrammen bei verschiedenen Geschwindigkeiten

Die Herleitung und Bedeutung der Stabilität, Kontrolle und Dämpfung ist in Abschnitt 2.2.3 beschrieben. In der KPI Berechnung des Postprocessings ist die Stabilität und Kontrolle bereits in ausgewählten Punkten berechnet worden. Im Fall der Stabilitäts- und Kontroll-Diagramme wird diese Ableitung an jeder Stelle des Diagramm errechnet und über das zugrundeliegende Giermomentdiagramm farblich abgestuft in der z-Ebene dargestellt. Die Darstellung und Interpretation wird in Unterkapitel 4.3 gezeigt.

4 Ergebnisse A: Analyse der erstellten Giermomentdiagramme

Giermomentdiagramme enthalten eine hohe Dichte an Informationen und liefern die Basis für vielfältige Analysemöglichkeiten. Grundlage für ein zuverlässiges Erstellen von Giermomentdiagrammen durch die Anwendung, ist ein stabiles Konvergenzverhalten des Simulationsmodells, das in Unterkapitel 4.1 überprüft wird. Die Giermomentdiagramme können durch die Anwendung für verschiedene Geschwindigkeiten und Längsbeschleunigungen simuliert werden. Die daraus resultierenden Unterschiede werden in Unterkapitel 4.2 untersucht. In Unterkapitel 4.3 wird auf die Interpretation der Stabilitäts, Kontroll- und Dämpfungsableitungen eingegangen. Dabei werden anhand von Contour-Diagrammen die fahrsituationsabhängige Veränderung der Größen aufgezeigt und Anwendungsbeispiele gegeben. Wie die KPIs der Giermomentdiagramme verwendet werden können um Parameterstudien durchzuführen, wird in Unterkapitel 4.4 gezeigt. Das Kapitel schließt mit einer Untersuchung zur Korrelation der Giermomentdiagramme mit aufgezeichneten Messdaten in Unterkapitel 4.5.

4.1 Konvergenzverhalten

Die Ergebnisse der Simulation können nur ermittelt werden, wenn es möglich ist, den geforderten Fahrzustand stabil einzuregeln. Aufgrund von mehreren simultan wirkenden Reglern und der möglichen Vorgabe von instabilen Fahrsituationen stellt das eine Herausforderung dar. Ein Konvergenzverhalten ohne Neigung zum Aufschwingen kann hauptsächlich durch die aufgelisteten Maßnahmen erreicht werden:

- Initialisierung der Fahrzeuggeschwindigkeit und Raddrehzahlen. Dies dient als Maßnahme um ein Aufziehen des I-Anteils des Geschwindigkeitsreglers zu verhindern und um große Regeleingriffe zu vermeiden.
- PT1-Verzögerung auf die Sollgrößen β_{ref} und δ_{ref} , um ein sprunghaftes Eingreifen des Giermomentreglers zu unterbinden. Die Parametrierung des Giermomentreglers kann dadurch stärker gewählt werden, um ein dynamischeres Führungsverhalten zu erreichen, ohne die Stabilität des Systems zu gefährden. Zudem ergibt sich durch die PT1-Verzögerung für alle in Neutrallage initialisierten Größen, wie z.B. die Federwege, ein kurzes Zeitfenster zum Abklingen des Einschwingungsverhalten, bevor das Fahrzeug in seinen gesuchten Fahrzustand eingeregelt wird.
- Parametrierung der PID Regler mithilfe von empirischen Einstellregeln [82, S.198-199].
- Kompensation der externen F_x -Kraft im Fall $a_{x,ref} \neq 0 \text{ m/s}^2$ durch eine Störgrößen-aufschaltung in den Geschwindigkeitsreglern [82, S.236-239].

- Verhindern des gegenseitigen Aufschwingens der Geschwindigkeits- und Giermomentregler. Dazu wird die Dynamik des Führungsverhaltens der Geschwindigkeitsregler gegenüber dem Giermomentregler reduziert um die Eigenfrequenzen zu trennen.

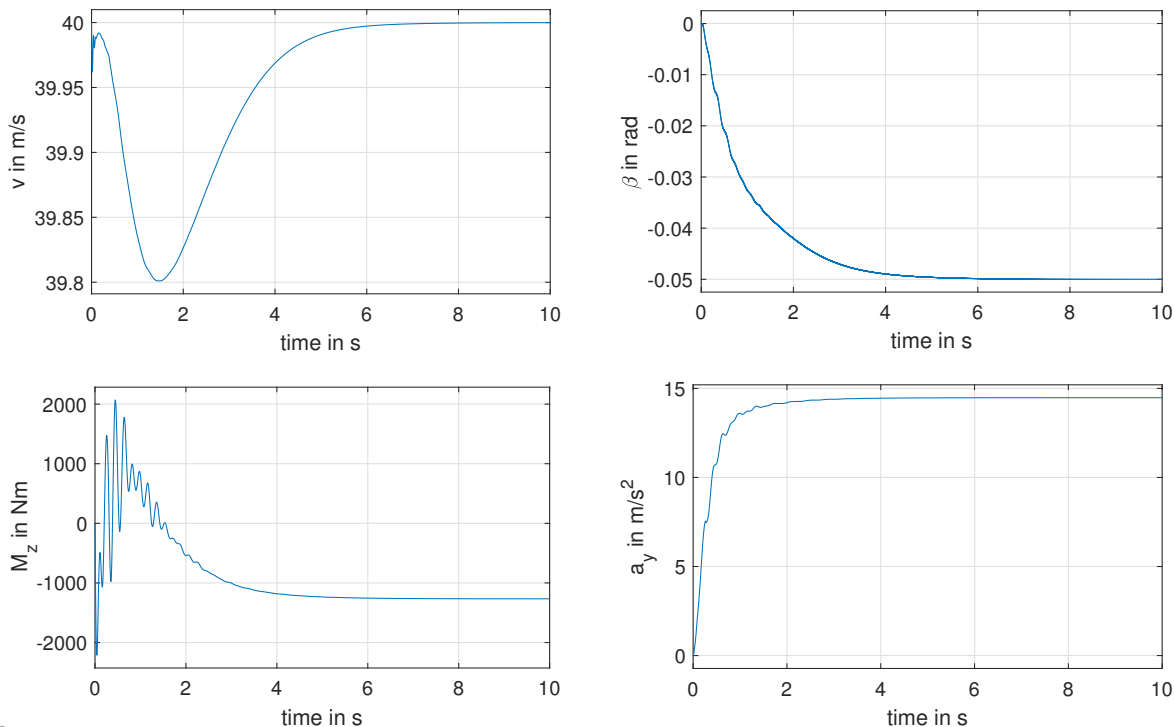


Abbildung 4.1: Konvergenzverhalten der Simulation für die Eingangsparameter $v = 40\text{ m/s}$, $\beta = -0.05\text{ rad}$, $\delta = 0.1\text{ rad}$. Nach 6,2s ist für die Ausgangswerte a_y und $M_z > 99\%$ des Endwertes erreicht.

Das finale Konvergenzverhalten der Simulation wird in Abbildung 4.1 gezeigt. Es sind keine Tendenzen zum Aufschwingen zu erkennen und die Sollgrößen werden ohne bleibende Regelabweichungen innerhalb der Simulationszeit erreicht. Die Ergebniswerte für a_y und M_z werden durch die Mittlung der letzten Sekunde der Simulation gebildet. Die durchschnittliche Laufzeit für 100 Ausführungen der Simulation liegt im Fall der Matlab Implementierung bei 24s und für die Python Implementierung bei 17s. Ist ein Mehrkernprozessor verfügbar, kann die Ausführungszeit in Python durch die Anzahl verfügbarer Threads geteilt werden.

4.2 Einfluss der Geschwindigkeit und Längsbeschleunigung

Mithilfe der Giermomentdiagramme ist eine ganzheitliche Untersuchung des Fahrzeugverhaltens möglich. Durch den Aufbau der Anwendung ist es einfach, Fahrsituationen bei unterschiedlichen Geschwindigkeiten und Längsbeschleunigungen zu untersuchen und zu vergleichen. Dabei wird für jede Kombination von vorgegebener Längsbeschleunigungen und Geschwindigkeiten das Postprocessing, beschrieben in Abschnitt 3.2.3, durchgeführt. Die Auswirkungen von zu untersuchenden Parameteränderungen werden dadurch nicht in einer isolierten Situation betrachtet, sondern können jederzeit ganzheitlich in verschiedensten Fahrsituationen bewertet werden. Dies ermöglicht die Identifizierung unterschiedlicher Sensitivitäten der Parameter in verschiedenen

Fahrsituationen und das Erkennen von fahrdynamischen Kompromissen, die bei der Änderung von Parametern eingegangen werden. In der vorliegenden Literatur wurde darauf kein Fokus gelegt [13, 37, 83]. Damit Fahrsituationen mit Längsbeschleunigung simulativ dargestellt werden können, ist es notwendig, dass das Reifenmodell kombinierte Längs- und Querkräfte abbilden kann. Die Grundlage dafür ist durch die Implementierung des Pacejka Reifenmodells gegeben, da kombinierte Lastzustände in Längs- und Querrichtung über Gewichtungsfaktoren modelliert werden. In Abbildung 4.2 wird der Einfluss der Geschwindigkeit und Längsbeschleunigung bei

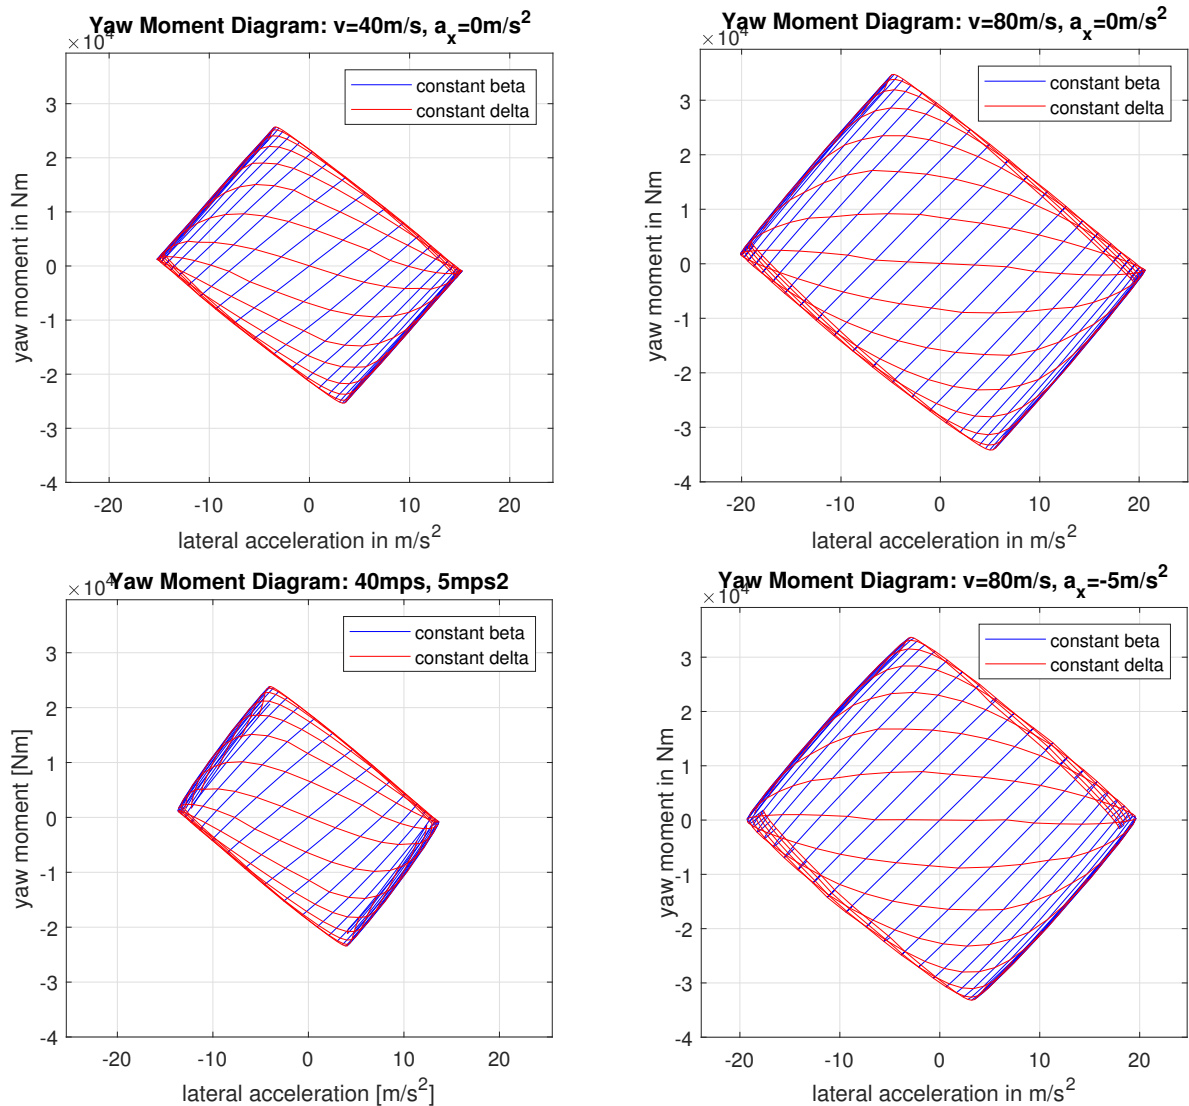


Abbildung 4.2: Einfluss der Geschwindigkeit v und Längsbeschleunigung a_x auf die Giermomentdiagramme. Links oben: $v = 40 \text{ m/s}$, $a_x = 0 \text{ m/s}^2$, Rechts oben: $v = 80 \text{ m/s}$, $a_x = 0 \text{ m/s}^2$, Links unten: $v = 40 \text{ m/s}$, $a_x = 5 \text{ m/s}^2$, Rechts unten: $v = 80 \text{ m/s}$, $a_x = -5 \text{ m/s}^2$,

konstanten Fahrzeugparametern gezeigt. Das gezeigte Fahrzeug ist der Devbot in seiner Basis-konfiguration. In der konstanten Kurvenfahrt mit $a_x = 0 \text{ m/s}^2$ ist das Grenzverhalten gutmütig und neigt zum Schieben über die Vorderachse. Das ist durch das negative Giermoment bei der maximalen positiven Querbewegung zu erkennen. Im Vergleich zwischen den Geschwindigkeiten $v = 40 \text{ m/s}$ und $v = 80 \text{ m/s}$ fällt auf, dass die maximale Querbewegung und das maximale Giermoment mit zunehmender Geschwindigkeit größer werden. Da sich die Radlast F_z aus der Gewichtskraft F_g und Abtriebskraft F_a nach Gleichung 4.1 zusammensetzt, erhöhen sich mit steigender Geschwindigkeit die möglichen Reifenkräfte, wodurch die Beobachtung erklärt

werden kann.

$$F_a = \frac{1}{2} c_a A \rho v^2 \quad (4.1)$$

Das Grenzverhalten bleibt über die Geschwindigkeit konstant und ist auch bei $v = 80 \text{ m/s}$ durch ein Schieben über die Vorderachse charakterisiert. In der Basiskonfiguration liegt sowohl die Gewichtsverteilung als auch die aerodynamische Balance zu 40% auf der Vorderachse, sodass die prozentuale Achslastverteilung über die Geschwindigkeit konstant bleibt.

Ist die Längsbeschleunigung $a_x \neq 0 \text{ m/s}^2$ werden höhere Längskräfte der Reifen erforderlich. Im Fall von positiver Längsbeschleunigung erfolgt die Aufbringung der erforderlichen Längskraft durch die Reifen der Hinterachse, im Fall von negativer Längsbeschleunigung durch alle Reifen im Verhältnis der eingestellten Bremskraftverteilung. In beiden Fällen ist das Reifenpotential für Querkräfte gegenüber der Fahrsituation bei gleicher Geschwindigkeit in der stationären Kurvenfahrt reduziert. Dadurch sinkt die maximale Querbeschleunigung und das maximale Giermoment. In beiden Fällen verändert sich das Grenzverhalten hin zu einem neutralem und im Fall der negativen Längsbeschleunigung leicht übersteuernden Grenzverhalten. Durch eine Kombination von Achslastverlagerung und Belastung der Reifen durch Längskräfte verliert die Hinterachse im Vergleich zur Vorderachse mehr Querkraftpotential, wodurch die Veränderung zu erklären ist. Die Gleichung 4.2 beschreibt den vereinfachten Zusammenhang der Achslastverlagerung bei konstant angenommener Schwerpunktshöhe.

$$\Delta F_z = \frac{m a_x C o G_z}{WB} \quad (4.2)$$

Der dynamische Achslastunterschied ΔF_z ist beim Beschleunigen und Bremsen von der Fahrzeugmasse m , der Längsbeschleunigung a_x , der Schwerpunktshöhe $C o G_z$ und dem Radstand WB abhängig. Die in diesem Kapitel beschriebenen Effekte, in Abhängigkeit der Geschwindigkeit und Längsbeschleunigung, sind als primäre Effekte zu verstehen. In Abhängigkeit der Modellkomplexität sind die Unterschiede durch weitere, sekundäre Effekte zu erklären.

4.3 Interpretation der Stabilität, Kontrolle und Dämpfung

Mithilfe der Contour-Diagramme zur Stabilität, Kontrolle und Dämpfung aus Abschnitt 3.2.3 kann ein Verständnis für das dynamische Verhalten des Fahrzeugs innerhalb des Manörraums gewonnen werden. Die Diagramme bieten die Möglichkeit, anderweitig schwierig zu beschreibendes Fahrverhalten zu quantifizieren und den Einfluss von Parameteränderungen innerhalb des Manörraums vergleichen zu können. Die vier Querkraft- und Giermomentableitungen für die Basiskonfiguration des Devbot sind in Abbildung 4.3 gezeigt.

In der Anwendung zeigt das Stabilitätsdiagramm dem Ingenieur in welchen Situationen sich das Fahrzeug stabil gegenüber Störungen im Schwimmwinkel verhält und in welchen Fahrsituationen das Verhalten instabil wird. Es ist einfach zu erkennen, dass die Stabilität im Bereich der Vorderachslimits (erster und dritter Quadrant) am höchsten ist, da die Hinterachse noch stabilisierendes Querkraftpotential besitzt. Im Bereich des Hinterachslimits ist die Stabilität negativ, da die Hinterachse kein weiteres Querkraftpotential mehr aufweist, ansteigende Querkraft an der Vorderachse zu stabilisieren. Das Diagramm der Kontrolle zeigt, wie hoch die Giermoment- oder Querbeschleunigungsantwort auf Lenkwinkeländerungen ist. Je höher das Giermoment,

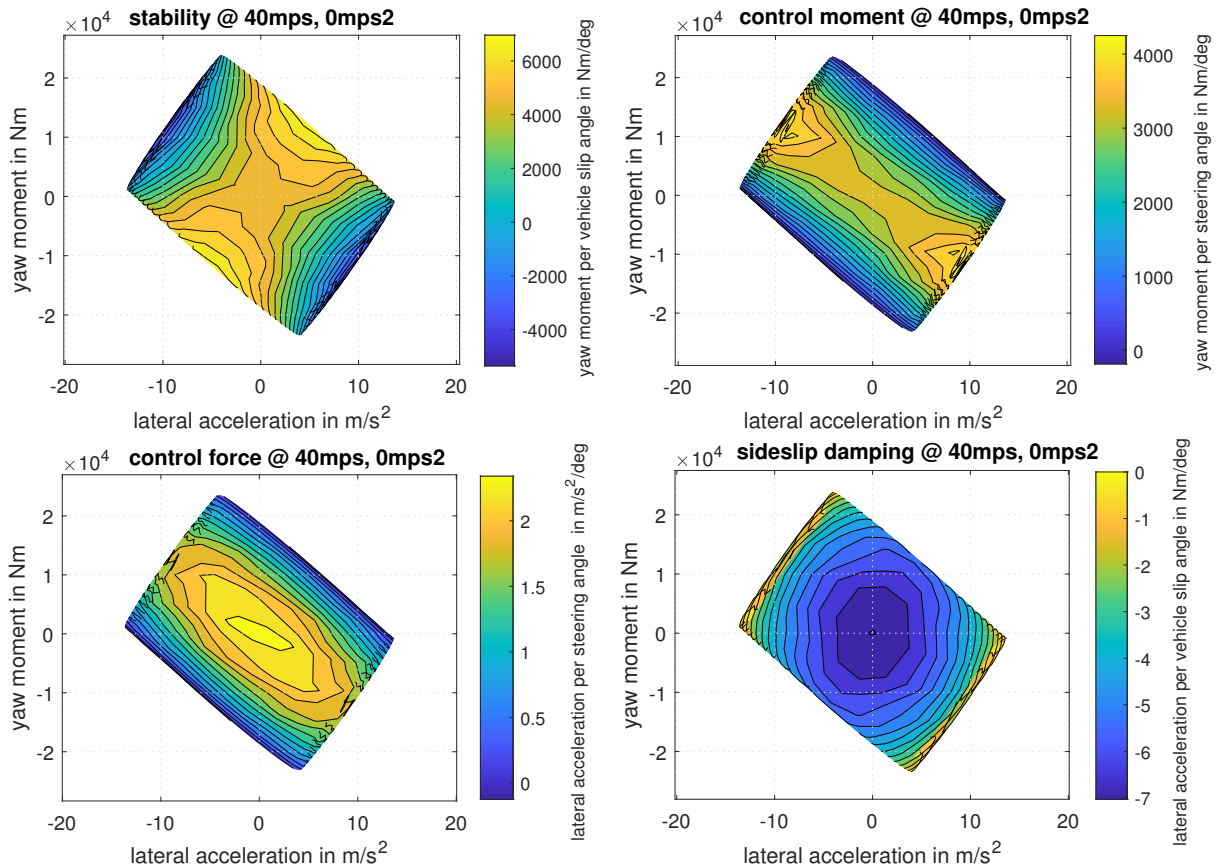


Abbildung 4.3: Stabilität, Kontrolle und Dämpfung innerhalb des Manöverraums

desto höher die Gierbeschleunigung und desto schneller ist die Fahrzeugreaktion. Je höher die Querschleunigung, desto schneller kann der effektive Kurvenradius reduziert werden. Qualitativ sind beide Diagramme zur Kontrolle ähnlich. Die höchsten Werte für die Kontrolle werden in der Geradeausfahrt oder in einer Lastwechselsituation erreicht. In diesen Situationen kann die Querkraftdifferenz zwischen Vorder- und Hinterachse maximiert werden. Die Kontrollmoment-Ableitung steigt im Vergleich zur Kontrollkraftableitung im Bereich des Hinterachslimits weiter an, da die Reduktion der Querkraft der Hinterachse das Gesamtgiermoment des Fahrzeugs steigert.

Die Schwimmwinkeldämpfungs-Ableitung ist in der Geradeausfahrt am höchsten und wird zu Null, wenn die Hinterachse an ihrem Querkraftmaximum ist, da an diesem Punkt die effektive Schräglaufsteifigkeit zu Null wird.

In der Praxis können die abgeleiteten Größen Setupänderungen messbar machen, indem sie das Fahrzeugverhalten quantifizieren. Denkbar ist beispielsweise folgendes Vorgehen: Das Fahrzeug zeigt immer an der selben Stelle des Kurses instabiles Fahrzeugverhalten mit Übersteuerreaktionen. In den Messdaten wird die Stelle lokalisiert an dem das ungewünschte Fahrzeugverhalten beginnt. Dazu wird das in v und a_x passende Giermomentendiagramm aufgerufen und mithilfe von β und δ die entsprechende Stelle im Diagramm gefunden. Eine Überlagerung mit dem Contour-Diagramm der Stabilität führt zum Wert der Stabilitätsableitung. Durch Setupänderungen in der Simulation kann die Veränderung der Stabilitätsableitung in dem zu untersuchenden Betriebspunkt untersucht werden, um das Fahrzeugverhalten in die gewünschte Richtung zu verbessern. Gleichzeitig wird durch die Anwendung jederzeit der Kompromiss der Änderungen in den anderen KPIs aufgezeigt. Bei einem effizienten Einsatz der Giermomentendiagramme zur Se-

tupfindung werden dadurch sowohl einzelne Fahrsituationen, als auch das globale Fahrverhalten betrachtet, um einseitige Setupentscheidungen zu verhindern.

Wie die Querkraft- und Giermomentableitungen das Verständnis des Fahrzeugverhaltens unterstützen können, lässt sich anhand eines extremen Fahrmanövers aus dem Rallyesport besonders anschaulich darstellen.

Anwendung des Scandinavian Flick im Rallyesport

Im Rallyesport wird die Fahrtechnik des Scandinavian Flick verwendet, um in Kurven mit geringem Kurvenradius die Gierrate zügig aufzubauen. Dazu wird das Fahrzeug während des Bremsvorgangs entgegengesetzt zur Kurve eingelenkt, um es beim Lösen der Bremse durch eine ruckartige Lenkbewegung in die Kurve hinein schleudern zu lassen. Abbildung 4.4 zeigt den Ablauf des Manövers.

Rallyefahrer erreichen dadurch hohe Gierraten im Bereich von $\dot{\psi} = 100 - 160^\circ/s$ [85] und können durch die schnelle Rotation um ihre z-Achse die Neuausrichtung der Fahrtrichtung zügiger abschließen und früher beschleunigen. Zudem bewirkt das erzeugte hohe Giermoment einen beschleunigten Aufbau des Schwimmwinkels und einen daraus resultierenden schnellen Aufbau der Querbearbeitung auf Untergründen mit überwiegend niedrigen Reibwerten. In Abbildung 4.5 wird der Zeitverlauf des Manövers im Giermomentdiagramm dargestellt und mit einem konventionellen Einlenken verglichen.




Abbildung 4.4: Durchfahren einer Kurve mit der Scandinavian Flick Technik [84]

Betrachtet man das Manöver unter Verwendung des Scandinavian Flicks, wird zuerst in die entgegengesetzte Richtung gelenkt, wodurch sich ein Schwimmwinkel aufbaut. Es entsteht ebenfalls eine Querbearbeitung in die entgegengesetzte Richtung der Kurve, weshalb der Flick meist in der Nähe der Kurveninnenseite angesetzt werden muss, um die Fahrbahnbreite ausnutzen zu können. Wird der Wechsel der Lenkrichtung schlagartig vollzogen, bewegt sich der Pfad im Giermomentdiagramm aufgrund der Gierträgheit des Fahrzeugs zunächst entlang einer Isolinie konstanten Schwimmwinkels. Dabei kommt das Fahrzeug in einen Fahrzustand in dem die Kontrolle besonders hoch ist, wie in Abbildung 4.3 zu erkennen ist. Zusätzlich wird dadurch gezielt eine instabile Situation durch eine Überlastung der Hinterachse herbeigeführt, wie in Stabilitätsdiagramm in Abbildung 4.3 zu erkennen ist. Im weiteren Verlauf bis zum Querbearbeitungsmaximum kann durch den Scandinavian Flick im Vergleich zum konventionellen Einlenken ein höheres Giermoment erreicht werden, wodurch die hohen Gierraten ermöglicht werden.

4.4 Parameterstudien

Parameterstudien werden im Motorsport häufig in der Konzeptentwicklung zur Sensitivitätsanalyse oder in der Fahrzeugabstimmung verwendet [29, S.22 ff.]. Häufig wird die Rundenzeit als zentrale Kenngröße betrachtet. Dabei muss ein Fahrzeug, das in der Simulation schnell ist, nicht unbedingt in der Realität schnell sein, wenn durch die Abstimmung die Fahrbarkeit beeinträchtigt wird. Die Rundenzeit hängt primär vom Längs- und Querbearbeitungspotential des Fahrzeugs ab. Die Fahrbarkeit ist schwieriger zu beschreiben und wird häufig hauptsächlich mithilfe




Abbildung 4.5: Vergleich des Einlenkverhaltens in eine Kurve mit und ohne die Anwendung des Scandinavian Flick. Startend von $[0,0]$ zeigt die blaue gestrichelte Linie ein normales Einlenken in eine Kurve, die grün gestrichelte Linie stellt das Einlenken über das Gegenpendeln mit der Scandinavian Flick Technik dar. Zur Vereinfachung erfolgt die Darstellung in einem Giermomentdiagramm ohne Längsbeschleunigungseinfluss.

von Fahrerfeedback bewertet. Die Stabilität und Kontrolle bietet dazu eine Quantifizierung, um das qualitative Fahrverhalten in verschiedensten Situationen zu beschreiben.

Mithilfe der in Abschnitt 3.2.3 vorgestellten KPI-Ableitung des Postprocessing können Parameterstudien mit Blick auf Querschleunigungspotential und Fahrbarkeit durchgeführt werden. Im Folgenden wird auf Basis des Devbot eine beispielhafte Parameterstudie durchgeführt. Die Basiskonfiguration bildet die Referenz. Verglichen werden eine Auswahl von KPIs bei drei verschiedenen Geschwindigkeiten im Fall der stationären Kurvenfahrt. Verglichen werden die Variationen der aufgeführten Parameter:

- Basiskonfiguration
- Gewichtsreduktion um 5% von 1160 kg auf 1102 kg
- Veränderung der Aerobalance um 2% in Richtung der Vorderachse
- Verwendung des TV-Faktor 50, beschrieben in Gleichung 3.3 im Vergleich zum inaktiven TV in der Basiskonfiguration
- Verbreiterung der Spurweite um 5% von $1,58\text{ m}$ auf $1,66\text{ m}$ an der Vorderachse und von $1,54\text{ m}$ auf $1,62\text{ m}$ an der Hinterachse
- Verlängerung des Radstands um 5% von $2,90\text{ m}$ auf $3,05\text{ m}$

In Abbildung 4.6 ist der Einfluss der Parameteränderungen auf die maximale stationäre Querschleunigung ($M_z = 0\text{ Nm}$) gezeigt. Die Gewichtsreduktion zeigt die zu erwartende Steigerung des Querschleunigung aufgrund der Degressivität des Reifenreibungswerts. Die Aerobalance und

das Torque Vectoring führen ebenfalls zu einer Steigerung der maximalen stationären Querbeschleunigung, weil die Untersteuertendenz im Grenzbereich, wie in Unterkapitel 4.4 gezeigt, reduziert wird. Durch die Balanceverschiebung kann die Hinterachse mehr Querkräfte absetzen, was zur Steigerung der stationären Querbeschleunigung führt. Die Spurweite und der Radstand haben keinen nennenswerten Einfluss auf das stationäre Querbeschleunigungspotential.




Abbildung 4.6: Einfluss verschiedener Parameteränderungen auf die maximale stationär erreichbare Querbeschleunigung

Da die Verbreiterung der Spurweite keinen Einfluss auf die stationäre Querbeschleunigung zeigt, wird in Abbildung 4.7 der Einfluss auf die maximale Querbeschleunigung gezeigt. Es zeigt sich, dass durch die Verbreiterung der Spurweite das maximale Querbeschleunigungspotential gesteigert werden kann. Die breitere Spurweite reduziert die Radlastunterschiede zwischen kurveninnerem und kurvenäußerem Rad. Aufgrund des degressiven Reifenreibungswerts wird dadurch die Summe der Querkräfte gesteigert. Um das gesteigerte Querbeschleunigungspotential in der stationären Kurvenfahrt abrufen zu können, sind weitere Setup-Anpassungen notwendig. Die Betrachtung der Aerobalance zeigt im Gegensatz zum stationären Zustand keinen Einfluss auf die maximale Querbeschleunigung, da der Betrag des Abtriebs konstant bleibt.




Abbildung 4.7: Einfluss verschiedener Parameteränderungen auf die maximale Querbeschleunigung

Abbildung 4.8 zeigt das resultierende Giermoment bei maximaler Querbeschleunigung. In der Basiskonfiguration liegt der Wert bei -1007Nm bei $v = 40\text{m/s}$. Das Limit der Vorderreifen ist bereits im Punkt der maximalen stationären Querbeschleunigung erreicht. Wird durch ein dynamisches Manöver versucht das Fahrzeug bei höheren Querbeschleunigungen zu bewegen, kann durch das verbliebene Querkraftpotential an der Hinterachse ein bis zu -1007Nm hohes Giermoment erzeugt werden. Das Fahrzeug schiebt über die Vorderachse und ist im Grenzverhalten untersteuernd [14, S.320]. Das Gewicht, die Spurweite und der Radstand haben nur eine geringe Auswirkung auf das Grenzverhalten. Die Aerobalance zeigt die zu erwartende Reduzierung des resultierenden Giermoments. Der Einfluss wird mit steigender Geschwindigkeit deutlicher, da der Anteil der Abtriebskraft in Bezug auf die Radlast steigt. Das Torque Vectoring zeigt den deutlichsten Einfluss auf das Grenzverhalten. Durch das zusätzliche Giermoment, das

durch die ungleiche Antriebsmomentverteilung an der Hinterachse entsteht, treten bei gleichem Lenkwinkel höhere Schwimmwinkel auf. Dadurch erreicht die Hinterachse im Grenzbereich zuerst ihr Querkraftlimit. Die Vorderachse kann bis zur maximal erreichbaren Querbewegung durch weiteres Querkraftpotential ein zusätzliches Giermoment von $M_z = 470Nm$ erzeugen. Dadurch wechselt das Grenzverhalten von untersteuernd zu übersteuernd.




Abbildung 4.8: Einfluss verschiedener Parameteränderungen auf das resultierende Giermoment am Punkt der maximalen Querbewegung

Die Ableitung der Stabilitäts-KPI im Punkt der maximalen stationären Querbewegung in Abbildung 4.9 zeigt qualitativ ein ähnliches Bild wie durch $M_z @ lim$ in Abbildung 4.8 dargestellt. Die Herleitung und grundsätzliche Erklärungen zur Stabilität und Kontrolle sind in Abschnitt 2.2.3 zu finden. Die Vorzeichen sind aufgrund der Vorzeichendefinition des Schwimmwinkels zur Betrachtung des Giermoments am Limit aus Abbildung 4.8 umgedreht. Bei positiven Querbewegungen ist der Schwimmwinkel im Grenzbereich negativ. Ein positiver Stabilitätswert bedeutet, dass das Fahrzeug auf eine Störung des Schwimmwinkels durch ein Giermoment antwortet, dass der Schwimmwinkeländerung entgegen gesetzt ist. Wird der Lenkwinkel konstant gehalten, stellt sich bei positivem Stabilitätsindex der Schwimmwinkel vor der Störung im Zeitverlauf wieder ein. Ist der Stabilitätsindex negativ, vergrößert sich der Schwimmwinkel ohne Korrekturen im Lenkwinkel unkontrolliert und es kommt zum Eindrehen des Fahrzeugs. Im Gegensatz zur Betrachtung des $M_z @ lim$, der die Stabilität am Limit gut darstellen kann, ist durch den Stabilitätsableitung die Stabilität in jedem Fahrzustand quantifizierbar.




Abbildung 4.9: Einfluss verschiedener Parameteränderungen auf die Stabilitätsableitung im Punkt der maximalen stationären Querbewegung

Die Kontrolle quantifiziert die Giermomentänderung durch Lenkwinkeländerungen. Je größer der Wert der Kontrolle, desto stärker reagiert das Fahrzeug auf Lenkwinkeländerungen. In Abbildung 4.10 wird der Einfluss der Parameter auf die Kontrolle in der Geradeausfahrt dargestellt. Durch die Gewichtsänderung reduzieren sich die Radlasten und dadurch die maximalen Reifkräfte. Die Kontrolle reduziert sich in Folge ebenfalls. In der Interpretation und im Rückschluss auf die Intensität der Fahrzeugreaktion auf Lenkwinkeländerungen sollte beachtet werden, dass

eine Gewichtsreduktion meist ebenfalls die Rotationsträgheit reduziert. Die Veränderung der Aerobalance führt zu erwartbaren, geschwindigkeitsabhängigen Steigerungen der Kontrolle. Die Änderung des Torque Vectoring führt ebenfalls zu einer Verbesserung der Kontrolle, da proportional zur Querbewegung zusätzliches Giermoment aus Reifenlängskräften erzeugt wird. Die Spurweite ist insensitiv auf die Kontrolle bei Geradeausfahrt. Durch die Verlängerung des Radstands kann eine Verbesserung der Kontrolle erwirkt werden. Der größere Hebelarm der Achsen zum Schwerpunkt führt zu größeren Giermomenten bei gleichen Reifenquerkräften. Wie bei der Gewichtsreduzierung ist zu beachten, dass die Verlängerung des Radstandes tendenziell zu einer Erhöhung des Rotationsträgheitsmoments führt, was die gewonnenen Agilitätsvorteile partiell kompensieren kann.




Abbildung 4.10: Einfluss verschiedener Parameteränderungen auf die Kontrollableitung im Punkt der maximalen stationären Querbewegung

Eine Betrachtung des maximalen Giermoments wird in Abbildung 4.11 gezeigt. Es zeigt sich, dass nur durch eine Verlängerung des Radstandes das maximale Giermoment signifikant erhöht werden kann. Insbesondere die Verschiebung der Aerobalance und das Torque Vectoring verbessern die Kontrolle in der Geradeausfahrt und in vielen der möglichen Fahrsituationen, können aber das maximale Giermoment nicht steigern.




Abbildung 4.11: Einfluss verschiedener Parameteränderungen auf das maximale Giermoment

4.5 Korrelation der Giermomentendiagramme mit Messdaten

Um die Validität der Giermomentendiagramme zu prüfen, wird eine Untersuchung mithilfe von Messdaten vorgenommen. Die Messgrößen v , a_x , β und δ bilden die Eingangsgrößen, um eine Nachsimulation durch die Giermomentendiagramm-Anwendung zu ermöglichen. Der Simulationsergebnis kann im Anschluss mit den Messwerten abgeglichen werden. Die Messdaten wurden während Testtagen auf den Rennstrecken in Modena und Montebalco mit dem Devbot im Jahr

2019 erhoben. In Abschnitt 4.5.1 wird die Korrelation der Querbewegung untersucht und in Abschnitt 4.5.2 die Korrelation des Giermoments. In Abschnitt 4.5.3 erfolgt eine Plausibilisierung der abgeleiteten Stabilitäts- und Kontrollwerte.

4.5.1 Korrelation der Querbewegung

Um die Korrelation mit realen Fahrzeugdaten zu überprüfen, wird durch eine Nachsimulation der Messdaten die Querbewegung ermittelt und kann der gemessenen Querbewegung gegenübergestellt werden. Da die Querbewegung eine direkte Ausgangs- und Messgröße darstellt, ist ein Vergleich ohne weitere Umrechnung möglich.

Im Preprocessing der Messdaten wurde besonderes Augenmerk auf eine korrekte Nulllage im Schwimmwinkel und Lenkwinkelsignal gelegt. Kam es auf den geraden Streckenabschnitten der Rennstrecken zu einem konstanten Offset wurden die Signale nachträglich neu genullt.




Abbildung 4.12: Vergleich der gemessenen Querbewegung des Devbots mit der nachsimulierten Querbewegung durch Giermomentdiagramm-Anwendung. Links: Modena 2019, Rechts: Monteblanco 2019

In Abbildung 4.12 ist die Korrelation zwischen gemessener und simulierter Querbewegung in zwei verschiedenen Ausschnitten der Erprobung mit den Devbot gezeigt.

Im Ausschnitt von Monteblanco ist in Rechtskurven (negative Querbewegung) eine gute Korrelation gegeben. Der Verlauf der simulierten Querbewegung folgt der gemessenen Querbewegung gut. Qualitativ und im Betrag stimmen die Verläufe überein. In der Linkskurve ist die Korrelation geringer ausgeprägt. Es ist zu erkennen, dass die gemessene Querbewegung höher ist als das Ergebnis der Nachsimulation. Die Simulation geht von einem konstanten Reibwert und einer ebenen Fahrbahnoberfläche aus. Kommt es zu Veränderungen im Fahrbahn-Reifen-Reibwert, zu Höhenunterschieden oder Änderungen in der Streckenneigung, hat das Auswirkungen auf die Reifenkräfte und führt zu Abweichungen in der Querbewegung. Besonders Höhenunterschiede und Streckenneigung können durch das Streckenprofil von Monteblanco eine Rolle spielen.

Im Beispiel von Modena kommt es nicht zu größeren absoluten Abweichungen. Es ist dennoch zu erkennen, dass zwischen der Simulation und den Messdaten teilweise ein Offset besteht. Dabei sind die Abweichungen innerhalb einer Kurve weitestgehend proportional zur Querbewegung. Dasselbe Verhalten lässt sich im Ausschnitt von Monteblanco beobachten. Es bleibt festzuhalten, dass die Simulation den Querbewegungsverlauf der Messdaten qua-

linitativ gut nachbilden kann. Es treten dennoch häufig proportionale Abweichungen auf, deren Ursache in einem abweichenden Fahrbahn-Reifen-Verhalten aufgrund der in Abschnitt 2.3.2 beschriebenen Ursachen vermutet wird. An diese Erkenntnis wird in Abschnitt 5.1.1 angeknüpft.

4.5.2 Korrelation des Giermoments

Die Untersuchung der Korrelation des Giermoments ist nicht in der gleichen Form wie für die Querbeschleunigung in Abschnitt 4.5.1 möglich, da das Giermoment nicht direkt gemessen werden kann. Das Giermoment kann für die Messdaten mithilfe der Differentialgleichung aus Gleichung 4.3 und Gleichung 4.4 berechnet werden. Das Giermoment setzt sich zusammen aus einem Teil, der von der Rotationsträgheit abhängt und einem Teil, der von der Gierdämpfung abhängt. Die Gierbeschleunigung $\ddot{\psi}$ ergibt sich aus der Differenzierung der Gierrate $\dot{\psi}$. Die Gierdämpfung ergibt sich aus den effektiven Schräglaufsteifigkeiten der Vorder- und Hinterachse sowie den Hebelarmen der Achsen zum Schwerpunkt und der Fahrzeuggeschwindigkeit. Bei der Ermittlung der effektiven Schräglaufsteifigkeiten ist zu beachten, dass diese im nichtlinearen Bereich des Reifens keine Konstante mehr darstellen.

$$M_z = I_z \ddot{\psi} + D_\psi \dot{\psi} \quad (4.3)$$

$$D_\psi = \frac{C_{\alpha,f,eff} l_f^2 + C_{\alpha,r,eff} l_r^2}{v} \quad (4.4)$$

Um die effektiven Schräglaufsteifigkeiten mithilfe des Reifenmodells zu jedem Zeitpunkt zu berechnen, sind neben den Schrägläufen Informationen zur Radlast F_z erforderlich. Aufgrund fehlender Sensoren zur Ermittlung der Radlasten stehen diese Daten nicht zur Verfügung, was die Berechnung des gierdämpfungsabhängigen Teils des Giermoments verhindert. In einem




Abbildung 4.13: Vergleich des berechneten Giermoments aus Messdaten des Devbots mit dem nachsimulierten Giermoment durch die Giermomentdiagramm-Anwendung. Die Schräglaufsteifigkeit zur Berechnung des Giermoments aus Messdaten ist als konstant angenommen.

Versuch, zumindest die Tendenzen zu vergleichen, wird die Rückrechnung des Giermoments aus den Messdaten mit einer konstanten Schräglaufsteifigkeit von $C_\alpha = 100.000 \text{ N/rad}$ durchgeführt. Diese Schräglaufsteifigkeit entspricht dem linearen Reifenverhalten des Devbots bei einer Radlast von $F_z = 5000 \text{ N}$. Das Ergebnis ist in Abbildung 4.13 gezeigt. Da die effektiven Schräglaufsteifigkeiten im nichtlinearen Bereich des Reifens abnehmen und beim Querkraftmaximum des Reifens den Wert Null annehmen, ist das aus den Messdaten berechnete Giermoment nach Gleichung 4.3 und Gleichung 4.4 zum Teil deutlich höher als das simulierte Giermo-

ment. Der trägheitsabhängige Teil des Giermoments nach Gleichung 4.3 ist im Vergleich zum dämpfungsabhängigen Teil für den Fall des Devbots betragslich zu vernachlässigen. Ebenfalls sind die Schräglaufsteifigkeiten von der Radlast F_z abhängig. Ein Vergleich des mit linearem Reifenverhalten rückgerechneten Giermoments mit dem simulierten Giermoment ist daher nicht im Detail möglich. Die Tendenzen stimmen zwar überein, aber die relativen Abweichungen schwanken deutlich. Weitere Schlüsse lassen sich deshalb nicht ableiten und von einer weiteren Untersuchung wird aufgrund des geringen Mehrwerts abgesehen.

4.5.3 Plausibilisierung von Stabilität und Kontrolle

Vergleichbar mit dem Vorgehen in Abschnitt 4.5.1 und Abschnitt 4.5.2, kann mithilfe einer Nachsimulation der Messdaten das Giermoment nach dem Schwimmwinkel und dem Lenkwinkel abgeleitet werden, um die jeweilige Stabilitätsmoment-Ableitung und Kontrollmoment-Ableitung zu erhalten. Werden diese mit den Messsignalen von Längs- und Querbefleunigung sowie Lenkwinkel und Schwimmwinkel verglichen, kann beurteilt werden, ob die Aussage der Stabilitäts- und Kontrollmoment-Ableitungen plausibel ist. Das Beispiel in Abbildung 4.14 ist ein Ausschnitt aus dem Testing in Montebianco von 2019, gefahren von einem menschlichen Fahrer. Um den Lesefluss zu verbessern, werden die beiden Ableitungsmetriken als Stabilität




Abbildung 4.14: Überlagerung der Messdaten des Devbots aus Montebianco 2019 mit den Stabilitäts- und Kontrollableitungen aus der Giermomentdiagramm Anwendung

und Kontrolle abgekürzt. Das Fahrzeug startet den Abschnitt mit einer Geradeausfahrt mit konstanter Geschwindigkeit. Ab 506s beginnt eine Verzögerung, wodurch die Stabilität steigt und die Kontrolle sinkt. Dieses Verhalten ist durch die Erhöhung der Gierdämpfung zu erklären, die invers von der Geschwindigkeit abhängig ist. Die Gierdämpfung ist in Gleichung 4.4 in Abschnitt 4.5.2 definiert. Ab 509s wird die negative Beschleunigung reduziert und das Fahrzeug beginnt den Einlenkvorgang. Mit steigender Querauslastung der Achsen reduziert sich die

Kontrolle und die Stabilität. Ab 511 s wird ein Querschleunigungsplateau erreicht. Dadurch, dass beide Metriken an diesem Punkt dem Wert Null nahe sind, wird vermutet, dass sich das Fahrzeug am Querschleunigungsmaximum befindet. Das Plateau der Querschleunigung an der Stelle bestätigt diese Vermutung. Im Bereich um 511 s fällt die Stabilität zwei Mal unter den Wert Null. Der erste Fall unter Null scheint klein genug zu sein, um keine merkliche Auswirkung zu verursachen. Der zweite, etwas größere Fall unter Null korreliert mit dem schnellen Anstieg des Schwimmwinkels, der durch eine entsprechende Reduzierung des Lenkwinkels abgefangen werden kann. Im Verlauf des Kurvenausgangs zwischen 512 – 518 s erhöhen sich die Kontrolle und Stabilität durch den Abbau der Querschleunigung. Im Bereich des Abbremsens für die nächste Kurve ab 518 s ist wieder die Zunahme der Stabilität und die Abnahme der Kontrolle durch die geschwindigkeitsabhängige Gierdämpfung zu erkennen. Beim Einlenken in die Kurve bei 522 s wird der Fahrer durch ein lockeres Heck überrascht und verzögert den Einlenkvorgang kurzzeitig. Das ist durch den kurzzeitigen Anstieg des Schwimmwinkels zu erkennen, der durch ein Zurückhalten im Lenkwinkel wieder abgefangen werden kann. Es zeigt sich, dass die Stabilität an diesem Punkt negativ und die Kontrolle positiv ist, was mit dem weiteren Messsignalen übereinstimmt. Eine positive Kontrolle bedeutet, dass die Vorderachse noch Querkraftpotential zu Verfügung hat und noch nicht an ihrem Maximum betrieben wird. Nachdem der Fahrer die erste kurzzeitig instabile Situation abgefangen hat, kann er den Lenkwinkel bis 523 s noch weiter erhöhen und die Vorder- und Hinterachse besser auslasten. Das Resultat ist eine leicht gestiegene Querschleunigung und eine Kontrolle und Stabilität nahe dem Wert Null. Da im Anschluss die Stabilität bei 523 s ein zweites Mal unter Null fällt, reagiert der Fahrer mit der Reduktion des Lenkwinkels. Der Wechsel von Linkskurve zu Rechtskurve ab 523 s passiert mit geringen Reserven in der Kontrolle, da das Fahrzeug zur Erzeugung des notwendigen Giermoments zum Richtungswechsel in der Nähe des Vorderachslimits operiert. Das geringe Kontrollniveau in der Nähe des Vorderachslimits ist in Abbildung 4.3 zu erkennen. Der Fahrer trifft den Kurvenscheitelpunkt bei 526 s gut, ohne dass Korrekturen notwendig sind. Der Schwimmwinkel baut sich flüssig auf und im Lenkwinkelsignal sind keine größeren Korrekturmaßnahmen zu erkennen. Die Stabilität und Kontrolle sinken beide auf den Wert Null was für die vollständigen Auslastung der Vorder- und Hinterachse spricht und dadurch vom Querschleunigungsmaximum an dem Punkt ausgegangen werden kann. Die Tatsache, dass die Stabilität zwischen 525 – 527 s nicht signifikant unter Null abfällt, korreliert mit der Beobachtung, dass keine Gegenlenkreaktionen im Lenkwinkelsignal zu erkennen sind.

Es kann resümiert werden, dass die Interpretation der nachsimulierten Stabilität und Kontrolle an markanten Zeitpunkten mit dem Verhalten des Fahrzeugs und der Reaktion des Fahrers übereinstimmt. Die Aussage der Stabilität und Kontrolle wird daher als grundsätzlich plausibel bewertet.

5 Methoden B: Echtzeitfähige Adaption von Messdaten

Auf Basis der Giermomentdiagramme wird ein modellbasierter Algorithmus zur Schätzung von Querbeschleunigungslimits vorgestellt. Unter der Verwendung eines neuronalen Netzes kann der Rechenaufwand deutlich gesenkt und der Algorithmus in Echtzeit ausgeführt werden. In Unterkapitel 5.1 wird die Hypothese und die Struktur des Schätzalgorithmus vorgestellt. Der Trainingsprozess des neuronalen Netzes wird separat in Unterkapitel 5.2 beschrieben.

5.1 Schätzung des Querbeschleunigungslimits des Gesamtfahrzeugs

Der Algorithmus verwendet die Giermomentdiagramme als Referenzinformation und schätzt das Querbeschleunigungslimit durch eine Skalierung des zugrundeliegenden Reifenmodells. Die getroffenen Annahmen werden in Abschnitt 5.1.1 vorgestellt. Darauf aufbauend wird die Architektur des Algorithmus entwickelt und in Abschnitt 5.1.2 aufgezeigt. Um die Rechenlast zu senken, sollen die Giermomentdiagramme vorsimuliert und durch ML Algorithmen zur Regression erlernt werden. In Abschnitt 5.1.3 werden verschiedene Algorithmen verglichen und das neuronale Netz als geeignetes Verfahren ausgewählt. In Abschnitt 5.1.4 erfolgt die Untersuchung von verschiedenen Methoden zur Skalierung des Reifenmodells. Die Schätzung der Querbeschleunigungslimits in der Anwendung auf Rundkursen geschieht örtlich und zeitlich differenziert. In Abschnitt 5.1.5 wird dazu die Erstellung von Reibwertkarten vorgestellt.

5.1.1 Hypothese

Die Giermomentdiagramm-Anwendung kann zur Nachsimulation von Messdaten verwendet werden. Durch Verwendung der Geschwindigkeit v_x , der Längsbeschleunigung a_x , des Schwimmwinkels β und des Lenkwinkels δ als Eingangswerte für die Giermomentdiagramm-Anwendung kann die Querbeschleunigung als Ergebnis ermittelt werden. Die simulierte Querbeschleunigung kann anschließend mit der gemessenen Querbeschleunigung verglichen werden, wie in Abbildung 5.1 gezeigt. Es ist zu erkennen, dass die gemessene Querbeschleunigung im Vergleich zu der nachsimulierten Querbeschleunigung eine proportionale Abweichung aufweist. Dieses Verhalten konnte bereits in Abschnitt 4.5.1 beobachtet werden. Das Problem besteht darin, dass die dem Reifenmodell zugrundeliegenden Reifendaten nur für die Umgebungsbedingungen gelten, unter denen sie aufgezeichnet wurden. Wenn sich z. B. die Strecke, die Temperatur, der Reifendruck usw. ändern, ändert sich das Reifenverhalten. Die exakte Reproduktion des Reifenverhaltens ist daher nur unter den gleichen Bedingungen möglich wie zum Zeitpunkt der Aufzeichnung der Reifendaten.




Abbildung 5.1: Gemessene Querbeschleunigung, die auf der Rennstrecke in Modena mit dem Devbot aufgezeichnet wurde, verglichen mit der nachsimulierten Querbeschleunigung

Die zugrundeliegende Annahme des in diesem Kapitel beschriebenen Algorithmus zum Schätzen von Querbeschleunigungslimits ist, dass Unterschiede in der Querbeschleunigung auf einen abweichenden Reibwert zwischen der Simulation und der Rennstrecke zurückzuführen sind. Der Reibwert des Fahrbahn-Reifen-Kontakts kann sich während des Fahrens durch viele Mechanismen ändern, wie bereits in Abschnitt 2.3.2 gezeigt. Durch Skalierung des Reifenmodells, das der Simulation zugrunde liegt, ist es daher möglich, die Ergebnisse der Simulation an die gemessenen Daten anzupassen. Da der Mechanismus der Reibwertveränderung nicht a priori bekannt ist, soll hierfür ein besonders allgemeingültiger Ansatz gewählt werden.

Eine weitere Annahme für die Auslegung des Algorithmus zur Schätzung der Querbeschleunigungslimits ist, dass es keinen global gültigen Reibungswert für eine Rennstrecke gibt. Die Reibwerte können lokal unterschiedlich sein, z. B. durch einen Abschnitt mit anderem Asphalt, Bereiche mit besonders hohem Reifenabrieb auf dem Belag oder eine Stelle mit leichter Kompression.

5.1.2 Architektur des Algorithmus

Der Aufbau der gesamten Softwarestruktur des TUM Autonomous Racing Teams ist in die Haupttasks Perception, Planning und Control aufgeteilt [86]. Innerhalb dieser drei Hauptblöcke sind alle Subtasks organisiert, die zusammen die autonome Fahrfunktion darstellen. Dabei stellt die Bahnfolgeregelung den primären Feedback Mechanismus dar. Das bedeutet, dass die Information über die maximale Querbeschleunigung als Feed-Forward Information vorhanden sein muss [40, S.16]. Über gute Erfahrungswerte über die Querbeschleunigungslimits kann mit einem solchem System eine gute Performance erreicht werden. Um zur Rundenzeitminimierung die Grenzen zu jederzeit voll ausnutzen zu können, muss das Fahrzeug die Fähigkeit besitzen die Limits fortlaufend neu zu bewerten. Eine Trajektorie besteht neben der Koordinatenvorgabe aus Informationen zur Geschwindigkeit und bildet den Eingang für den Control Block. Um die Geschwindigkeit passend zur Trajektorie zu planen, ist die maximal erzielbare Querbeschleunigung eine wichtige Information, wie durch Gleichung 2.17 gezeigt. Es erschließt sich deshalb, dass der Algorithmus zur Schätzung von Querbeschleunigungslimits als Vorverarbeitung der Daten im Bereich des Planning Blocks angesiedelt ist.

Der Algorithmus soll in der Lage sein, durch den Vergleich der gemessenen und simulierten Querbeschleunigung das Querbeschleunigungslimit in Echtzeit abzuschätzen. Die Nachsimulation der Messdaten ist aus Rechenzeitgründen nicht in Echtzeit auf dem Fahrzeug möglich. Die Simulations-Anwendung der Giermomentendiagramme benötigt im Durchschnitt 200 ms für die Simulation eines Eingabedatensatzes. Die Aktualisierungsfrequenz der Messsignale ist in der Regel wesentlich geringer und liegt, abhängig von der Konfiguration, im Bereich von $1 - 10\text{ ms}$. Eine Implementierung der Giermomentendiagramm-Anwendung direkt auf dem Fahrzeug würde zu einer erheblichen Rechenlast führen und könnte nur mit einer geringen Aktualisierungsfrequenz und einer Selektion der vorhandenen Daten betrieben werden. Daher wird der in Abbildung 5.2 vorgestellte Ansatz verwendet, um Echtzeitfähigkeit zu erreichen.

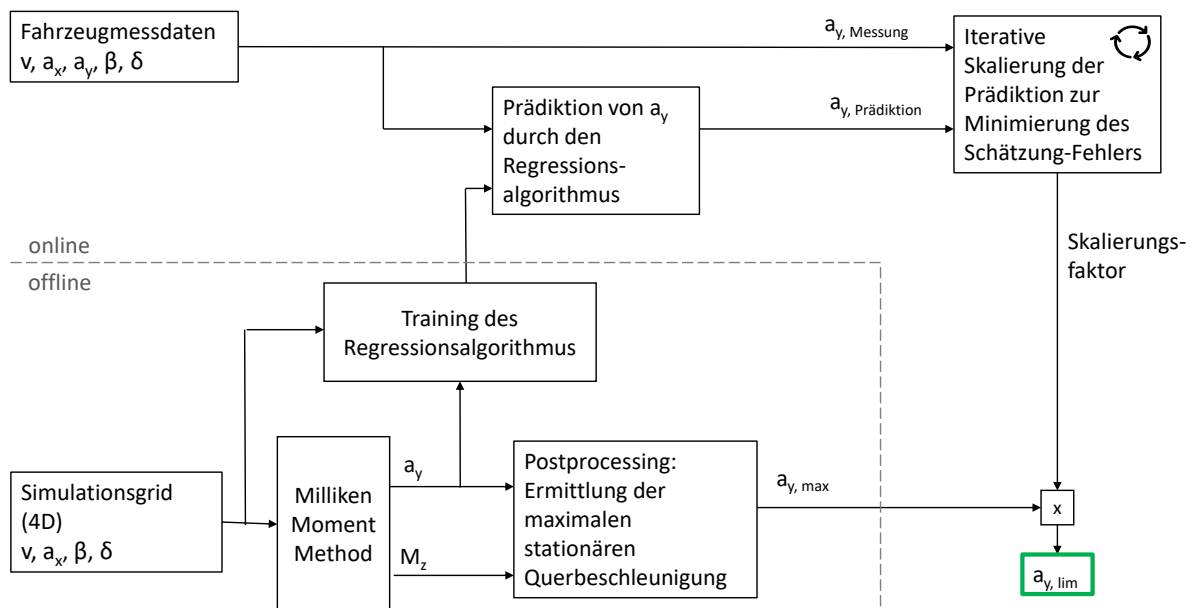


Abbildung 5.2: Strukturdiagramm des Algorithmus zur Schätzung von Querbeschleunigungslimits

Um die Rechenlast auf dem Fahrzeug zu reduzieren, werden Giermomentendiagramme mit feiner Auflösung der Eingangsmerkmale vorsimuliert. Es ist zu beachten, dass der gewählte Bereich der Eingangsmerkmale jederzeit den erwarteten Betriebsbereich abdecken kann. Die resultierende Ergebnismatrix wird anstelle der direkten Nachsimulation der Sensordaten am Fahrzeug verwendet. Mit Hilfe eines offline trainierten Regressionsalgorithmus kann die Ergebnismatrix für Zwischenschritte im Fahrbetrieb zur Prädiktion ausgewertet werden. Die gemessene und prädizierte Querbeschleunigung kann so verglichen und mit Hilfe von Fehler-Metriken auf Ähnlichkeit bewertet werden.

Gemäß der Hypothese, dass die Abweichung der Querbeschleunigung durch eine Abweichung des Reibwertes verursacht wird, kann ein Skalierungsfaktor gefunden werden, der die Ausgabe der Simulation am besten an die Sensordaten annähert. Der Skalierungsfaktor ist gleichbedeutend mit einer Skalierung des maximalen Reibwertes des Reifenmodells. Im Fall der in Abschnitt 5.1.4 ausgewählten Skalierungsmethode für das Reifenmodell führt eine Skalierung des Reifenmodells in der Simulation oder eine Multiplikation des Simulationsergebnis der Querbeschleunigung mit dem Skalierungsfaktor zum selben Ergebnis. Das ermöglicht die in Abbildung 5.2 präsentierte Struktur.

Die Multiplikation des Skalierungsfaktors mit der maximalen stationären Querschleunigung, die durch das Offline-Postprocessing der Giermomentendiagramme berechnet wurde, ergibt die Schätzung der Querschleunigungslimits und damit das Ergebnis des Algorithmus. Es ist zu beachten, dass die maximale Querschleunigung von der Geschwindigkeit abhängig ist. Das Ergebnis ist folglich nicht ein einzelner Querschleunigungswert, sondern ein Array mit den maximalen Querschleunigungen in Abhängigkeit von der Geschwindigkeit.

5.1.3 Regressionsverfahren

Mit Hilfe von Regressionsalgorithmen kann die Ergebnismatrix der Giermomentendiagramme im Online-Betrieb auf dem Fahrzeug mit wesentlich niedrigerem Rechenaufwand ausgewertet werden im Vergleich zur einer Online-Nachsimulation. Bei der Auswahl eines passenden Algorithmus liegt der Fokus auf der Regressionsgüte und der Ausführungsgeschwindigkeit. Das Modul Scikit-learn für Python bietet einige High-Level Toolboxen für Machine Learning Algorithmen. Sie basiert auf den Modulen *NumPy* und *SciPy*, die in ihrem Kern auf geschwindigkeitsoptimierten C-Code basieren und dadurch eine hohe Ausführungsgeschwindigkeit ermöglichen [87]. Eine Stärke ist die Vielzahl an verschiedenen Regressionsalgorithmen, die einen umfassenden Vergleich ermöglichen. Als Trainingsdaten, für einen Vergleich von verschiedenen Algorithmen, wird eine hochaufgelöste Ergebnismatrix der Giermomentendiagramm-Anwendung verwendet. Die Festlegung des Wertebereichs der Eingangsmerkmale ist entsprechend der im Fahrbetrieb des Roborace Fahrzeug auftretenden Werte gewählt und in Tabelle 5.1 dargestellt.

Tabelle 5.1: Wertebereich der Eingangsmerkmale für die Simulation

Merkmal	Max/Min	Schritte
v	10/60 $\frac{m}{s}$	26
a_x	-14/7 $\frac{m}{s^2}$	22
β	$\pm 0.10 rad$	80
δ	$\pm 0.17 rad$	80

Nach einer ersten Untersuchung verschiedener ML Algorithmen haben sich folgende Ansätze als passend für die Anwendung herausgestellt und werden weiter untersucht:

- Nearest Neighbour (Referenz)
- k-Nearest Neighbour Regressor (Scikit-learn)
- Lineare Regression (Scikit-learn)
- Multi Layer Perceptron (MLP) Regressor (Scikit-learn)

Das Training der Algorithmen auf einen Datensatz läuft in Scikit-learn grundsätzlich nach dem selben Schema ab. Jeder Regressionsalgorithmus besitzt als Objekt eine Methode *train*, an die der Trainingsdatensatz, aufgeteilt in die Eingangsmatrix X_{train} und dem Ergebnisvektor Y_{train} , zusammen mit weiteren Parametern für den Trainingsprozess übergeben werden kann. Die Matrix X_{train} besteht aus den Eingangsmerkmalen a_x , v_x , β und δ . Y_{train} besteht aus a_y , dem Ergebnis der Simulation.

Aufgrund der geringen Schrittweite der Eingangsmerkmale kann als einfachste Variante, ohne die Verwendung des Scikit-learn Package, ein Nearest Neighbour Ansatz implementiert werden. Für jedes der vier Eingangsmerkmale wird der nächstgelegene Index der Simulation gesucht, wodurch der entsprechende Wert der Ergebnismatrix gefunden werden kann. Das Codebeispiel in Code 5.1 verdeutlicht das Vorgehen durch den Algorithmus. Eine Regression oder Interpolation

ist durch den Ansatz nicht möglich. Die Stärke des Ansatzes liegt in der Einfachheit und wird deshalb als Referenz verwendet.

Code 5.1: Funktionsdefinition des Nearest Neighbour Algorithmus

```

1     def nearest_neighbour(ax, v, beta, delta, ax_range, v_range,
2     beta_range, delta_range, ay_array):
3         idx_a = find_nearest(ax_range, ax)
4         idx_v = find_nearest(v_range, vx)
5         idx_b = find_nearest(beta_range, beta)
6         idx_d = find_nearest(delta_range, delta)
7
8         ay = ay_array[idx_a, idx_v, idx_b, idx_d]
9
10        return ay

```

Der durch Scikit-learn implementierte k-Nearest Neighbour Algorithmus greift auf dasselbe Konzept zurück und ist im Detail in Abschnitt 2.4.1 erklärt. Durch die Mittlung der gefundenen Punkte der Anzahl k kann eine Interpolation des Ergebnis erreicht werden. Bei der Mittlung der Punkte kann eine uniforme oder eine vom Abstand abhängige Gewichtung vorgegeben werden. Da die vier Eingangsmerkmale einen unterschiedlich starken Einfluss auf das Ergebnis haben und damit der Abstand keine belastbare Metrik für die Gewichtung darstellt, wird die uniforme Gewichtung gewählt. Für den Parameter k wird für einen Kompromiss aus Geschwindigkeit und Interpolationsverhalten $k = 5$ verwendet.

Die Implementierung der linearen Regression erfordert die Vorgabe des Grades des Polynoms. Mit der Kombination der Scikit-learn Module *MakePipeline* und *PolynomialFeature*, kann das Modul *LinearRegression* zur Polynomregression verwendet werden. Es ist zu vermuten dass eine Lineare Regression 1. Ordnung nicht für das Anlernen des Trainingsdatensatz geeignet ist, da die zugrundeliegenden Zusammenhänge nicht von linearer Natur sind. Bei der Betrachtung der Giermomentdiagramme ist das durch den Verlauf der Linien konstanten Lenkwinkels ersichtlich, die keinem linearen Verlauf folgen. Da der Einfluss der Geschwindigkeit auf die aerodynamischen Kräfte auf das Fahrzeug quadratisch ist, wird der Einfluss des Merkmals v in 2. Ordnung oder höher vermutet. Die Überlegungen zu den Merkmalen δ und v zeigen, dass es erforderlich ist, ein Polynom höherer Ordnung an den Trainingsdatensatz anzupassen. Zur Ermittlung der erforderlichen Ordnung des Polynoms werden aufgrund der Punktsymmetrie der Ergebnismatrix verschiedene ungerade Ordnungen miteinander vergleichen und mit dem Nearest Neighbour Algorithmus als Referenz verglichen. Das beste Ergebnis konnte mit einem angepassten Polynom 5. Ordnung erreicht werden und wird deshalb als Basis für den Vergleich mit den anderen Regressionsalgorithmen verwendet.

Der letzte Regressionsalgorithmus im Vergleich ist der MLP Regressor. Das MLP ist ein voll vernetztes neuronales Netzwerk. Der Trainingsprozess und die Optimierung der Hyperparameter ist im Fall des MLP umfangreicher und wird daher in Unterkapitel 5.2 gesondert betrachtet. Neuronale Netzwerke besitzen den Vorteil, Zusammenhänge innerhalb des Datensatzes im Trainingsprozesses eigenständig zu lernen und eignen sich dadurch besonders für die Anpassung an komplexe, nichtlineare Zusammenhänge.

Das Verhalten der Regressionsverfahren in der Anwendung mit Realfahrzeugdaten wird in Abbildung 5.3 gezeigt. Der Nearest Neighbour Algorithmus zeigt ein zu erwartendes, sprunghaftes Verhalten, dass sich aufgrund nicht implementierter Interpolation aus der Schrittweite der




Abbildung 5.3: Vergleich des Regressionsverhalten der verschiedenen ML Algorithmen. Der Nearest Neighbour Algorithmus nimmt keine Regression vor, sondern zeigt das jeweils räumlich nächste Simulationsergebnis. Es ist daher als Referenz anzusehen.

Simulation ergibt. Im Falle des Vergleichs wird der Nearest Neighbour Algorithmus daher als Referenz angesehen, da er die direkten Ergebnisse der Simulation verwendet. Der k-Nearest Neighbour Algorithmus kann durch die Mittlung eine Abstufung vornehmen und die Sprünge im Verlauf sind im Vergleich zum Nearest Neighbour Verfahren kleiner. Das Prädiktionsverhalten ist wie erwartet und dem eigenentwickelten Nearest Neighbour-Algorithmus ähnlich. Obwohl die lineare Regression den von einem Polynom zu erwartenden kontinuierlichen Verlauf zeigt, liegt die Prädiktion deutlich neben den Ergebnissen der Referenz. Daraus lässt sich schließen, dass der zugrundeliegende Zusammenhang nicht zufriedenstellend durch ein Polynom 5. Ordnung mit linearen Koeffizienten angenähert werden kann. Das Regressions-MLP zeigt ebenfalls eine kontinuierliche Vorhersage, die jedoch im Bereich der Referenz liegt. Für einen Vergleich wird mithilfe der Fahrdynamiksimulation des TUM Autonomous Racing Teams eine virtuelle Runde auf dem Rundkurs von Modena simuliert. Die durch die Regressionsalgorithmen geschätzte Querbeschleunigung wird mithilfe des R^2 Werts gegenüber der simulierten Querbeschleunigung auf ihre Anpassungsgüte bestimmt. Mit Ausnahme der linearen Regression erreichen die Algorithmen eine sehr gute Anpassung, mit einem leichten Vorteil für das MLP. Als Ursache wird der stetigere Verlauf der Prädiktion des MLP im Vergleich zu den Nearest Neighbour Ansätzen vermutet. Die Ergebnisse in Bezug auf den R^2 Wert und die Rechenzeit in Relation zu Implementierung des Nearest Neighbour Algorithmus sind in Tabelle 5.2 gezeigt. Im Bezug auf

Tabelle 5.2: Leistungsfähigkeit der Regressionsalgorithmen im Vergleich

Algorithmus	R^2 Wert	Rechenzeit
Nearest Neighbour	0.9972	100%
k-Nearest Neighbour Regressor	0.9978	7.7%
Linear Regression	0.9216	0.5%
Multi Layer Perceptron Regressor	0.9981	2.6%

die durchschnittliche Rechenzeit zeigt sich die Optimierung der Scikit-learn Algorithmen deutlich.

Aufgrund des guten Ergebnisses, sowohl in Regressionsgüte und der Geschwindigkeit, wird der MLP Regressor als Regressionsalgorithmus ausgewählt.

5.1.4 Skalierung des Reibwertes

Das Ziel des Algorithmus zur Schätzung der Querschleunigungslimits ist die Ermittlung eines Skalierungsfaktors für den maximalen Reibwert des Reifenmodells um die Abweichung zwischen gemessener und prädizierter Querschleunigung zu minimieren. Dazu wird der maximale Reibwert des Reifenmodells in einer Schleife iteriert und mithilfe einer geeigneten Metrik bewertet.

Zur Skalierung des maximalen Reibwertes des Reifenmodells werden zwei Ansätze verglichen. Die verwendete Implementierung des Pacejka Reifenmodell beinhaltet bereits Parameter zur Skalierung des maximalen Reibwertes. Dieses Vorgehen wird im folgenden Prescaling genannt. Als alternative Skalierungsmethodik wird die Multiplikation des Ausgangs des Pacejka Modells mit dem Skalierungsfaktor verwendet. Dieses Vorgehen wird im folgenden Postscaling genannt. Beide Skalierungsmethoden können damit den maximalen Reibwert variieren, verhalten sich jedoch unterschiedlich in Bezug auf Schräglaufsteifigkeit und α -Position des maximalen Reibwertes, wie in Abbildung 5.4 zu erkennen ist.




Abbildung 5.4: Vergleich der Reifenskalierungsmethoden. Links: Prescaling durch die Parameter des Pacejka Modells. Rechts: Postscaling durch Skalierung des Ausgangs des Pacejka Modells.

Bei der Verwendung des Prescaling durch den internen Skalierungsfaktor des Pacejka Modell verändert sich die Schräglaufsteifigkeit um den Nullpunkt herum nicht. Steigt der Schräglaufwinkel an, bleibt die Schräglaufsteifigkeit bis kurz vor dem Erreichen des Querkraftmaximums vom Skalierungsfaktor unabhängig. Der Hochpunkt verschiebt sich hingegen in Bezug auf seine α -Position in Abhängigkeit vom Skalierungsfaktor. Das Postscaling verhält sich umgekehrt. Die α -Position des Hochpunkts bleibt unabhängig vom Skalierungsfaktor konstant, dafür verändert sich die Schräglaufsteifigkeit.

In Abschnitt 2.3.2 wurde bereits darauf aufmerksam gemacht, dass es noch keinen wissenschaftlichen Konsens in Bezug auf die Veränderung des Reifenverhaltens bei wechselndem Reibwert gibt. Es scheint, dass unterschiedliche Ursachen qualitativ andere Auswirkungen auf das Reifenverhalten haben. Als empirisches Reifenmodell ist das Pacejka Modell nur belastbar für den Reibwert bei dem die Daten zur Anpassung des Modells erhoben wurden [33]. Die Ska-

lierungsmethodik des Pacejka Modell basiert auf physikalisch-mathematischen Überlegungen und wird bei der empirischen Anpassung des Modells durch Messdaten nicht beeinflusst [19].

Da die Ursache der Veränderung des Reibwert zum Zeitpunkt der Schätzung nicht bekannt ist und demnach die passende Skalierungsmethodik nicht weiter eingegrenzt werden kann, besteht die Aufgabe darin, eine universell anwendbare und robuste Skalierungsmethode passend für den Anwendungsfall zu finden. Dazu werden in einer Untersuchung sieben Ausschnitte aus verschiedenen Messdatensätzen der Testtage in Montebianco, Modena und Croix-en-Ternois mit dem Devbot aus 2019 untersucht. Dabei wird mit jedem Datensatz Tabelle 5.3 die beste Anpassung durch beide Skalierungsmethoden gegenübergestellt.

Tabelle 5.3: Vergleich der Skalierungsmethoden in verschiedenen Ausschnitten aus Messdaten des Devbots. Der MAE- und R^2 -Wert der besten Anpassung für beide Methoden mit resultierendem Skalierungsfaktor f_s ist aufgeführt.

Methodik Messung	Prescaling			Postscaling		
	f_s	MAE [m/s^2]	R^2	f_s	MAE [m/s^2]	R^2
Montebianco, 29.04.2019, Run06, 708-715s	0,82	0,74	0,95	0,92	0,66	0,96
Montebianco, 29.04.2019, Run06, 766-775s	0,85	0,86	0,97	0,94	0,78	0,98
Modena, 16.05.2019, Run05, 235-238s	0,61	1,92	0,82	0,69	0,66	0,97
Modena, 16.05.2019, Run05, 360-365s	1,40	0,63	0,94	1,12	0,46	0,95
Modena, 16.05.2019, Run05, 374-384s	1,21	1,10	0,94	1,06	1,17	0,94
Croix-en-Ternois, 08.11.2019, Run05, 205-220s	0,34	0,87	0,54	0,41	0,39	0,91
Croix-en-Ternois, 08.11.2019, Run05, 615-624s	0,46	0,60	0,85	0,64	0,38	0,95

Liegt die Schätzung im Bereich nahe um den Skalierungsfaktor Eins, kann mit beiden Skalierungsverfahren eine gute Anpassung erreicht werden. Dabei tendiert die Schätzung durch das Prescaling zu größeren Anpassungen, der Skalierungsfaktor des Postscalings liegt näher am Wert 1.

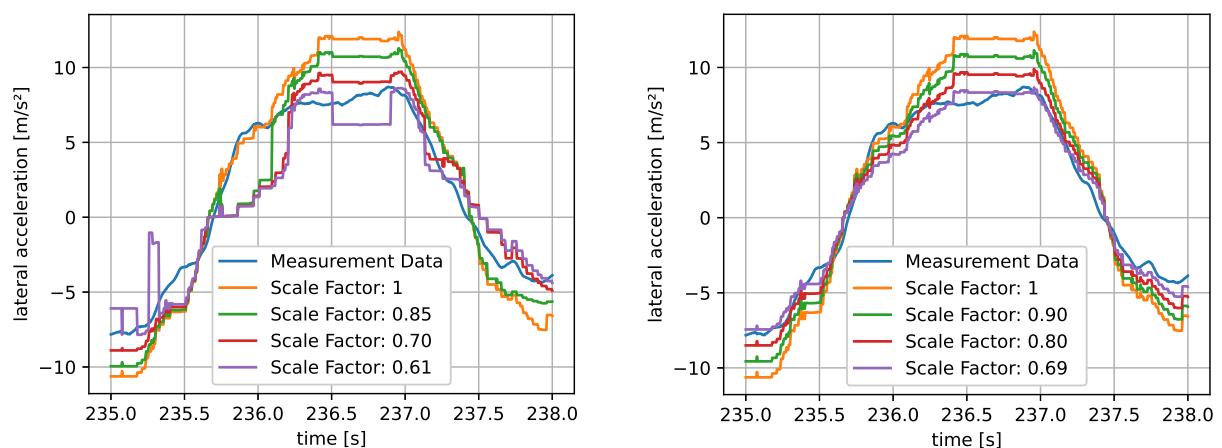


Abbildung 5.5: Annäherung von niedrigen Reibwerten durch die Skalierungsmethoden. Links: Prescaling durch die Parameter des Pacejka Modells. Rechts: Postscaling durch Skalierung des Ausgangs des Pacejka Modells. Messdaten: Modena, 16.05.2019, Run05, 235-238s

Bei größeren Abweichungen vom Skalierungsfaktor Eins, zeigen sich Probleme bei der Verwendung des Prescalings. Ist der Reibwert deutlich geringer, kann mithilfe des Prescalings der Querbeschleunigungsverlauf nicht mehr nachgebildet werden. In Abbildung 5.5 ist das Verhalten zu erkennen. Der Bereich in dem der Schräglaufwinkel einen Einfluss auf die Querkraft besitzt, wird bei niedrigen Skalierungsfaktoren mit der Prescaling-Methode ebenfalls klein. Sind die Schrägläufe in dem Messdaten größer als der Schräglauf-Wert des skalierten Maximums der

Querkraftkurve, so hat der Schräglauf keinen Einfluss mehr auf die Querkraft. Querkraftveränderungen können im Bereich der Sättigung nur noch über Radlastschwankungen herbeigeführt werden. Je stärker der Skalierungsfaktor im Prescaling vom Wert Eins abweicht, desto stärker werden die Verzerrungen im prädizierten Querbeschleunigungsverlauf.

Ist der Reibwert deutlich höher, kann der Querbeschleunigungsverlauf durch das Prescaling ebenfalls schlecht angenähert werden. Es zeigt sich, dass durch die Verschiebung des Hochpunkts der Querkraft auf höhere Werte des Schräglaufwinkels eine weitere Erhöhung des Skalierungsfaktors keine weitere Reduzierung des Fehlers nach sich zieht. In dem Fall rutscht der Hochpunkt der Querkraft in einen Bereich des Schräglaufwinkels, der in den Messdaten nicht mehr vorkommt. Das Prescaling wird bei hohen Skalierungsfaktoren demnach insensitiv gegenüber Änderungen im Skalierungsfaktor.

Tabelle 5.4: Durchschnittliche Leistungsfähigkeit der Skalierungsmethoden im Vergleich

Skalierungsmethodik	MAE [m/s^2]	R ²
Prescaling	0.96	0,85
Postscaling	0.64	0,95

Die durchschnittliche Leistungsfähigkeit der beiden Skalierungsmethoden wird in Tabelle 5.4 gegenübergestellt. Die Ergebnisse deuten darauf hin, dass bei Anwendung auf reale Rennstreckenszenarien mit einer Vielzahl von möglichen Einflüssen auf den Reibwert, die Postscaling-Methode die robustere Skalierungsmethode darstellt. Aus diesem Grund wird das Postscaling für die Anwendung im Algorithmus zur Schätzung des Querbeschleunigungslimits verwendet.

5.1.5 Erstellung von Reibwertkarten

Die Schätzung der Querbeschleunigung mithilfe des vorgestellten Algorithmus erfordert die Betrachtung eines Zeitintervall T , um nicht aufgrund von Effekten wie Messrauschen, starken Schwankungen zu unterliegen. Die Strecke wird daher in Sektoren unterteilt, für die jeweils eine Schätzung durchgeführt wird. Die Unterteilung erfolgt anhand von klassifizierten Fahrzuständen, wie beispielsweise *Bremsen*, *Bremsen + Lenken*, *Rollen + Lenken* durch eine bestehende Funktion in der Fahrzeugsoftware. Die Unterteilung findet vor dem Fahrtbeginn statt und ist während der Fahrt nicht veränderlich. Die Sektorengrenzen werden über die X/Y -Koordinate im raumfesten Streckenkoordinatensystem und über die Distanzkoordinate s definiert.

Im Fahrbetrieb überwacht ein Beobachter die aktuelle Fahrzeugposition. Wird eine Sektorengrenze überfahren, kann mit den gespeicherten Messdaten aus dem letzten Sektor die Schätzung der Querbeschleunigungslimits durchgeführt werden. Mit der Schätzung wird die Reibwertkarte aktualisiert. Der Aufbau der Reibwertkarte wird in Abbildung 5.6 gezeigt. Da die Schätzung im Fahrbetrieb immer für den abgeschlossenen Sektor erfolgt, hat die Aktualisierung der Reibwertkarte erst einen Einfluss auf die Planung der Trajektorie der nächsten Runde. Dadurch können lokale Reibwertunterschiede und zeitlich langsam ablaufende Effekte, wie beispielsweise die Reifenabnutzung oder die Veränderung der Reifentemperatur, erfasst werden. Der Fokus liegt auf dem Zusammenspiel mit der Trajektorienplanung, die für ihren Planungshorizont örtlich zugeordnete, maximale Beschleunigungslimits verwendet. Die Trajektorie wird kontinuierlich neu geplant und daher ist es notwendig, die Beschleunigungsgrenzen für den Planungshorizont im Voraus zu kennen. Für eine schlagartige Veränderung des Reibwerts, beispielsweise durch ein Ölleck oder einen Reifenplatzer, ist der Algorithmus nicht geeignet.

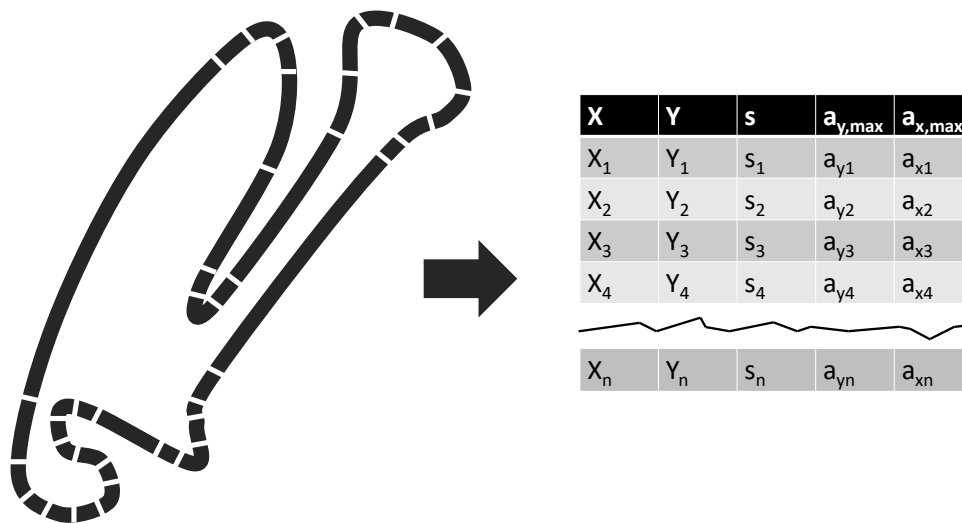


Abbildung 5.6: Struktureller Aufbau der Reibwertkarten. Die geschätzten Querschleunigungslimits werden über X/Y-Koordinaten und die Distanzkoordinate s den Sektoren zugewiesen.

5.2 Trainingsprozess des neuronalen Netz

Der Trainingsprozess für das MLP zur Regression läuft nach dem üblichen Schema für das Anlernen von ML Algorithmen ab. Der Ablauf ist in Abbildung 5.7 dargestellt.

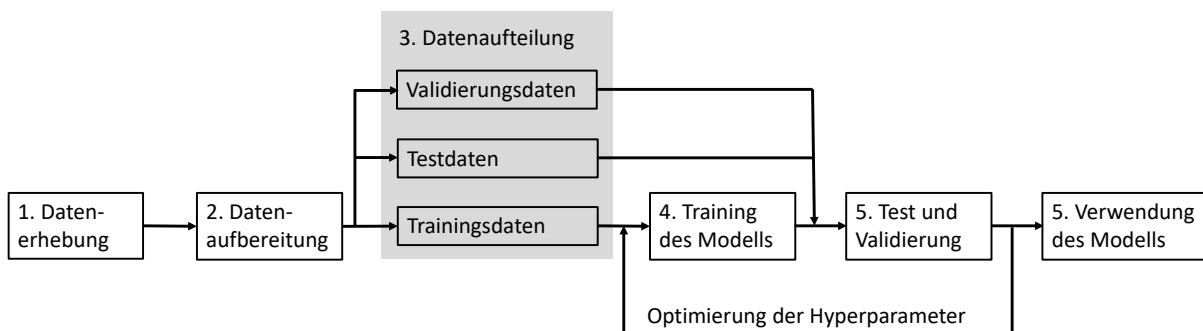


Abbildung 5.7: Trainingsablauf für das Training von Machine Learning Algorithmen [88, S.22]

Die Datenerhebung erfolgt durch Daten aus hochaufgelösten Giermomentdiagrammen. Eine feine Abstufung der Wertebereiche der vier Eingangsmerkmale a_x , v , β , δ , stellt eine detaillierte Datenbasis dar, mithilfe der das MLP das Fahrzeugverhalten lernen kann. Die erforderliche Breite der Wertebereiche leitet sich aus Messdaten ab und deckt den üblichen Operationsbereich des Fahrzeugs ab. Insgesamt umfasst ein Trainingsdatensatz 3.660.800 Zeilen. Der verwendete Wertebereich ist in Tabelle 5.1 dargestellt.

In der Datenaufbereitung erfolgt die Standardisierung der Daten. Sind die Wertebereiche der Eingangsmerkmale nicht im selben absoluten Wertebereich, kommt es zu einer Verzerrung im Trainingsprozess eines Neuronalen Netzes, da das Merkmal mit den größeren absoluten Werten eine höhere Gewichtung erfahren würde. Um das Problem der Verzerrung aufgrund der Größenordnung der Eingangsmerkmale zu lösen, wird als Vorverarbeitungsschritt für die Daten eine Skalierung durchgeführt. Die Normierung, auch z-Mittelwert-Normierung genannt, konvertiert die Daten in einen Mittelwert von Null und eine Standardabweichung von Eins [71, S.146]. Es ist wichtig zu beachten, dass bei der Verwendung des trainierten Netzes die selbe

Skalierung der Eingangswerte vorgenommen werden muss.

$$X_{ij} = \frac{X_{ij} - \mu}{\sigma} \quad (5.1)$$

Hierbei steht X_{ij} für den Datenpunkt im Index i , μ für das arithmetische Mittel im Datensatz X in der Spalte j und σ für die Standardabweichung im Datensatz X in der Spalte j .

Grundsätzlich sollte die Leistungsfähigkeit eines ML Algorithmus nicht mithilfe von Daten bewertet werden, auf denen der Algorithmus trainiert wurde. Daher wird der Datensatz aufgeteilt mithilfe eines *Train-Val-Test-Splits*. Üblich ist ein 75/25% Split für die Trainings- und Validierungsdaten [73, S.169]. Dabei werden 75% der Daten für das Training des Algorithmus und 25% für die Evaluierung mithilfe einer geeigneten Metrik verwendet. Es können auch andere Verhältnisse gewählt werden. Dabei ist es zu beachten, dass das Trainingsset so groß wie möglich gewählt wird, ohne dass der Validierungsdatensatz eine Größe unterschreitet, ab der die Aussage statistisch insignifikant wird [73, S.169]. Die finale Beurteilung nach Auswahl eines geeigneten Netzes erfolgt auf dem bis dahin ungesesehenen Testdatensatz.

Das Training des MLP erfolgt im Rahmen der gesetzten Hyperparameter. Oft ist die richtige Kombination entscheidend für die Leistungsfähigkeit des ML-Algorithmus. Da es zur Auswahl der optimalen Hyperparameter keine universelle Vorgehensweise gibt [73, S.48], ist häufig die systematische Iteration das übliche Vorgehen. Zur Untersuchung eines Parameterraums sind, neben der manuellen Anpassung der Hyperparameter, die Grid Search oder die Random Search häufig verwendete Algorithmen. Mit einer Grid Search wird jede Position im Parameterraum evaluiert. In der Random Search wird der Parameterraum begrenzt und zufällige Kombinationen der Hyperparameter untersucht. *Bergstra* und *Bengio* konnten empirisch und theoretisch nachweisen, dass zufällig gewählte Versuche effizienter sind für die Optimierung von Hyperparametern als Versuche in einem Gitter [89]. Die Random Search ermöglicht die Untersuchung von größeren Parameterräumen im Vergleich zur Grid Search, bei gleichzeitig geringerem Zeitaufwand. In dieser Arbeit wird daher die Random Search zur Hyperparameteroptimierung verwendet. Die Trainingsergebnisse werden in Unterkapitel 6.1 vorgestellt.

Im Training wird zusätzlich auf einige Techniken zurückgegriffen, die das Training effizienter gestalten und das Ergebnis verbessern können. Diese werden im folgenden vorgestellt:

Cross Validation

Eine Alternative Strategie für den *Train-Val-Test-Split* ist die *k-fold Cross Validation*. Hierzu wird der Datensatz in k -gleiche Datensätze unterteilt. Für jeden Teildatensatz wird das Training auf den restlichen Datensätzen durchgeführt und der ausgewählte Datensatz bildet den Validierungsdatensatz. Das Training findet dann auf den $k - 1$ Datensätzen statt und kann im Anschluss mit dem Validierungsdatensatz beurteilt werden. Im Anschluss sollte noch eine weitere Beurteilung auf dem bisher ungesesehenen Testdatensatz stattfinden. Der Fehlerwert wird für jede Konstellation berechnet und anschließend gemittelt. Der Vorteil gegenüber dem klassischen Train-Test-Split liegt darin, dass alle Daten zum Training verwendet werden können. Ebenso steigt die Robustheit des Trainingsprozess, da das Risiko für eine Überanpassung auf den Trainingsdatensatz reduziert wird [72, S.82]. Abbildung 5.8 verdeutlicht das Vorgehen.

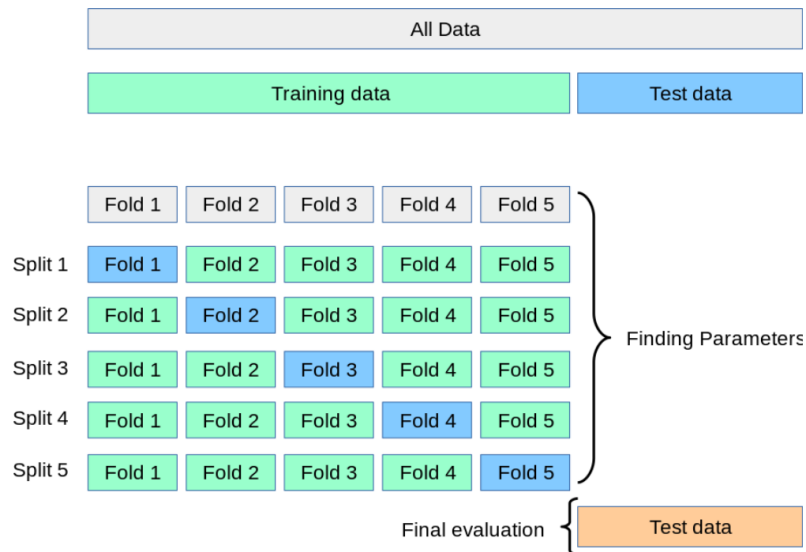


Abbildung 5.8: Unterteilung der Datensätze bei einer 5-fold Cross Validation [90]

L2 Regularisierung

Mithilfe der L2 Regularisierung kann einer Überanpassung auf die Trainingsdaten entgegenge- wirkt werden, indem im Training die Sensitivität auf einzelne Datenpunkte gedämpft wird. Der L2 Penaltyterm α beschränkt die Größe der Gewichtsparameter des Netzwerks, da große Werte üblich ein Zeichen von Überanpassung sind [91]. Das Netzwerk erhält dadurch einen höheren Bias und in der Konsequenz wird die Varianz der Ergebnisse reduziert. Je nach gewählter Größe des Penaltyterms α wird dadurch der durchschnittliche Fehler der Schätzung reduziert.




Abbildung 5.9: Auswirkung des Penaltyterms α auf die Generalisierungsfähigkeit des Netzes. Links ist der Trainingsdatensatz zu sehen, in den weiteren Abbildungen ist jeweils die Prädiktion des Netzes überlagert. Im Bild ist als Ergebnis der normalisierte Genauigkeitswert der Prädiktion durch das Netz mit dem jeweiligen Penaltyterms α zu sehen. Der bestmögliche Wert der normalisierten Genauigkeit ist Eins.

Uniforme Initialisierung

Die Initialisierung der Gewichte und Bias-Werte ist von großer Bedeutung für das Trainingsergebnis. Beispielsweise würde eine Initialisierung aller Gewichts- und Bias-Faktoren des Netzwerks auf dem Wert Null dazu führen, dass keine Lernen möglich ist und der Trainingsprozess dadurch blockiert wäre [92]. Die Initialisierung ist deshalb von Bedeutung, da sie den Lernprozess entscheidend beeinflusst. Bei ungeeigneter Wahl der Initialisierung kann es zum *Exploding/Vanishing Gradient* Problem kommen, bei dem die einzelnen Neuronen eine sehr geringe oder zu hohe Lernrate aufweisen und den Lernprozess behindern [93]. Um diesem Umstand zu verhindern, kommt die uniforme Initialisierung nach *Glorot* zum Einsatz [94].

6 Ergebnisse B: Echtzeitfähige Adaption von Messdaten

Der vorgestellte Algorithmus zur Schätzung von Querschleunigungslimits wird mithilfe von Messdaten und in der Software-in-the-Loop (SiL) Umgebung auf seine Validität und Ungenauigkeit geprüft. In Unterkapitel 6.1 werden die Ergebnisse der Hyperparameteroptimierung im Training des neuronalen Netz vorgestellt. Unterkapitel 6.2 schließt an mit Untersuchungen des Algorithmus mit Messdaten und in Open-Loop und Closed-Loop Simulationen.

6.1 Training des neuronalen Netzes

Das Training des Multi Layer Perceptron erfolgt durch eine Random Search zur Optimierung der Hyperparameter. Die Trainingsdauer wird dabei auf 350 Epochen begrenzt. Aus Vorversuchen hat sich diese Dauer als ausreichend herausgestellt. Dazu wird eine Abbruchbedingung gesetzt, die einen Abbruch das Trainings auslöst, wenn sich der Verlust des Netzes über 20 Epochen nicht mehr um $RMSE > 0.01 m/s^2$ verbessert, um eine Überanpassung zu verhindern. Für einen robusteren Trainingsprozess wird eine 5-fache Cross Validation eingesetzt, wie in Unterkapitel 5.2 beschrieben. Der Suchraum wird durch die folgenden Parameter definiert:

Tabelle 6.1: Wertebereich für den Parametersuchraum der Random Search

Parameter	Wertebereich
Anzahl Hidden Layer (Tiefe)	3-15 Layer
Neuronen je Layer (Breite)	20-100 Neuronen
Aktivierungsfunktion	identity, sigmoid, tanh, relu
L2 Penalty	0.0001-0.1

Die Basis für die folgende Auswertung wird aus 250 trainierten Netzen aus dem Suchraum aus Tabelle 6.1 und zusätzlich 200 trainierten Netzen mit Fokus auf die relu Aktivierungsfunktion gebildet. Zuerst erfolgt die Auswertung zu den Aktivierungsfunktionen. Tabelle 6.2 zeigt dazu die gruppierten Ergebnisse. Der RMSE Fehler ist dabei über die fünf Cross Validation Iterationen gemittelt.

Tabelle 6.2: Ergebnisse der verschiedenen Aktivierungsfunktionen im Vergleich

Aktivierungsfunktion	Ø RMSE [m/s^2]	Ø Trainingszeit [s]	Ø Evaluierungszeit [s]
identity	2.759	252	0.08
sigmoid	5.067	431	0.27
tanh	0.324	955	0.53
relu	0.322	659	0.10

Besonders die identity und sigmoid Aktivierungsfunktionen sind nicht in der Lage das Fahrzeugverhalten mithilfe der Trainingsdaten zu erlernen, was sich durch den hohen RMSE Wert zeigt. Im Fall der identity Aktivierungsfunktion ist das nachvollziehbar, da es sich um eine lineare Funktion handelt die ein nichtlineares Problem nur begrenzt lernen kann. Das schlechte Abschneiden der sigmoid Aktivierungsfunktion konnte bereits durch *Glorot* und *Bengio* beobachtet werden. Sie zeigten, dass bei der Anwendung in tiefen Neuronalen Netzwerken die sigmoid Aktivierungsfunktion dazu neigt, den ersten Layer während des Trainings in die Sättigung zu treiben [94]. Die tanh und relu Aktivierungsfunktionen schneiden in Bezug auf die Qualität der Schätzung vergleichbar ab. Die relu Aktivierungsfunktion benötigt im Vergleich zum Training und in der Evaluierung weniger Zeit. Besonders die Evaluierungszeit ist interessant, da sie ein Maß für die Geschwindigkeit in der Verwendung des Neuronalen Netzes darstellt. Aufgrund der höchsten durchschnittlichen Prädiktionsgüte und der geringeren Laufzeitanforderungen ist die relu Aktivierungsfunktion für die Echtzeitanwendung im Betrieb auf dem Fahrzeug am besten geeignet. Die weiteren Untersuchungen erfolgen daher auf Basis der relu Aktivierungsfunktion und sind alle auf die identische Stichprobe bezogen.

Die Auswirkungen des L2 Penaltyterms auf den RMSE Fehler der Prädiktion wird durch Abbildung 6.1 gezeigt. Es zeigt sich ein Vorteil durch eine leichte Regularisierung im Bereich




Abbildung 6.1: Boxplot Diagramm zu den Trainingsergebnissen bei einer Variation der L2 Regularisierung

von $\alpha = 10^{-3} - 10^{-2}$. Darüber und darunter verschlechtert sich die durchschnittliche Güte der Schätzung und die Streuung der Ergebnisse nimmt zu.

Für das Erlernen des Fahrzeugverhaltens, das durch die Giermomentdiagramm-Anwendung beschrieben wird, wird ein Netz einer bestimmten Größe benötigt, um die Komplexität der Trainingsdaten in das Netz zu übertragen. Abbildung 6.2 zeigt die Abhängigkeit der Schätzungsgüte von Neuronenanzahl. Es ist zu erkennen, dass durch eine Steigerung der Netzgröße die durchschnittliche Schätzungsgüte zunimmt und die Streuung der Ergebnisse abnimmt. Niedrige RMSE-Fehler treten bereits bei einer Netzwerkgröße von 300 Neuronen auf, sind aber weniger häufig und hängen vermutlich von der Verteilung der Neuronen im Netzwerk ab. Im Bereich von 300 bis 600 Neuronen sind durchweg gute Ergebnisse zu erreichen. Die Wahrscheinlichkeit von guten Ergebnissen ist Bereich von 500 Neuronen nochmal leicht erhöht. Ab einer Netzgröße von 600 Neuronen und aufwärts ist eine Verschlechterung der Schätzungsgüte zu beobachten. Die Gründe hierfür sind nicht vollständig bekannt. Da es sich bei den Netzen mit 700 Neuronen ebenfalls um die tiefen Netze mit 14-15 Layern handelt, lässt sich vermuten, dass entweder die Größe oder die Tiefe des Netzwerks die Lernfähigkeit behindert. Im nächsten Schritt wird die




Abbildung 6.2: Boxplot Diagramm zu den Trainingsergebnissen für unterschiedliche Netzgrößen

Frage beantwortet, ob für die effizienteste Allokation der Neuronen die Tiefe oder die Breite des Netzwerks priorisiert werden sollte. In Abbildung 6.3 ist die Abhängigkeit der Schätzungsgüte von der durchschnittlichen Netzwerkbreite dargestellt. Für den Breitenparameter können die

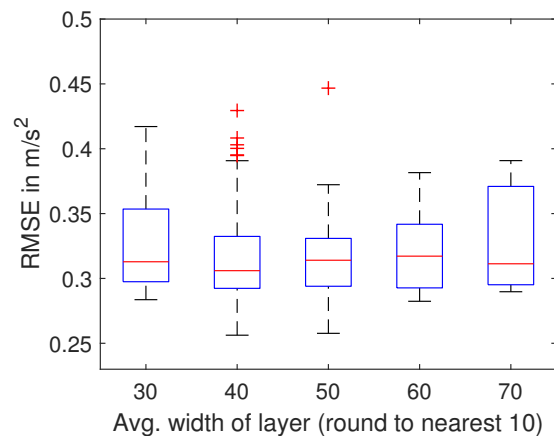


Abbildung 6.3: Boxplot Diagramm zu den Trainingsergebnissen in Abhängigkeit von der durchschnittlichen Netzwerkbreite

besten Ergebnisse für eine durchschnittliche Breite von 40-50 Neuronen erreicht werden. In Abbildung 6.4 ist die Abhängigkeit von der Tiefe des Netzwerks dargestellt. Bis zu einer Netz-




Abbildung 6.4: Boxplot Diagramm zu den Trainingsergebnissen in Abhängigkeit von der Netzwerktiefe

werktiefe von sieben Layern lässt sich eine Verbesserung der Schätzungsgüte beobachten. Zwischen 7-14 Layern ist durchweg eine gute Netzwerkqualität zu erreichen.

Die Auswahl des besten Netzes erfolgt über ein Ranking anhand des über alle fünf Cross Validation Iterationen gemittelten RMSE Werts. Die Leistung des besten Netzwerks wird anschließend anhand des Testdatensatzes durch zuvor ungesehene Daten überprüft. Die Ergebnisse sind dazu in Tabelle 6.3 gezeigt. Das Validierungsergebnis ist dabei erwartbar mit $RSME = 0.25 m/s^2$ etwas besser als der Testergebnis von $RSME = 0.30 m/s^2$. Interessant sind die Ergebnisse, wenn das Netz mit identischen Hyperparametern, aber mit 100% der Trainingsdaten trainiert wird. Die Cross Validation entfällt in diesem Fall. Das Validierungsergebnis entspricht damit dem Trainingsverlust im letzten Trainingsschritt und ist erwartbar geringer, da die verwendeten Daten zur Validierung den Trainingsdaten entsprechen. Beachtenswert ist, dass sich das Testergebnis auf dem bisher ungesehenen Testdatensatz von $RSME = 0.30 m/s^2$ auf $RSME = 0.22 m/s^2$ verbessert, im Vergleich zum Trainingsprozess mit Cross Validation. Die Gründe hierfür werden in der Qualität der Trainingsdaten vermutet. Die Trainingsdaten sind synthetisch erzeugt und liefern durch die konstanten Umgebungsbedingungen in der Simulation jederzeit Ergebnisse frei von Messrauschen, was ein intensiveres Training ermöglicht.

Tabelle 6.3: Trainingsergebnisse bei Training mit und ohne Cross Validation. Im Fall mit Cross Validation ist das Validierungsergebnis gemittelt über alle Iterationen. Im Fall der vollständigen Verwendung der Trainingsdaten ist das Validierungsergebnis gleich dem Trainingsverlust der letzten Epoche

Trainingsstrategie	Validation RMSE [m/s^2]	Test RMSE [m/s^2]
5-fold Cross Validation	0.25	0.30
100% Trainingsdaten	0.09	0.22

Im Bezug auf die üblicherweise auftretenden Querbeschleunigungen im Rennbetrieb liegt der Fehler im Bereich von 1 – 3%. Da bei dem Fehler von einer Normalverteilung auszugehen ist und die Schätzung der Querbeschleunigung gemittelt über einen Sektor erfolgt, wird der bleibende Fehler als akzeptabel eingestuft.

6.2 Schätzung der Querbeschleunigungslimits

In Abschnitt 6.2.1 wird der Algorithmus in Anwendungsbeispielen vorgestellt und auf Schwächen untersucht, die die Validität der Schätzung beeinträchtigen. In Abschnitt 6.2.2 werden die Querbeschleunigungslimits in der SiL-Umgebung an den Trajektorienplaner zurückgeführt und die Sicherheitsvorkehrungen für die Closed-Loop Anwendung vorgestellt. In Abschnitt 6.2.3 erfolgt eine Untersuchung zur Streuung der Schätzung in Abhängigkeit verschiedener Parameter.

6.2.1 Anwendung des Algorithmus

Der vorgestellte Algorithmus zur Schätzung von Querbeschleunigungslimits kann mit Messdaten aus den Testtagen aus dem Jahr 2019 mit dem Devbot in Modena, Montebianco und Croix-en-Ternois und mit Simulationsdaten aus der Fahrdynamiksimulation untersucht werden. Beide Datenquellen bieten ihre individuellen Vorteile. Die Daten aus der Fahrdynamiksimulation sind dabei aufgrund der begrenzten Modellkomplexität teilweise idealisiert. Dafür sind die Umgebungsbedingungen jederzeit konstant und einzelne Parameter können gezielt variiert werden.

Ein Abgleich mit Messdaten ermöglicht darüber hinaus das Betrachten aller nicht modellierten Effekte. Im Rahmen der Arbeit konnten keine dedizierten Messdaten für die Validierung des Schätzalgorithmus aufgenommen werden. Anders als bei Simulationsdaten entfällt dadurch die Kenntnis über den maximalen Reibwert.

Zuerst erfolgt die Überprüfung, ob der Algorithmus mithilfe des angelernten neuronalen Netzes in der Lage ist, den Querbeschleunigungsverlauf nachzubilden. Als Referenz dienen dabei die Daten aus der Fahrdynamiksimulation. Da das neuronale Netz ebenfalls auf Basis von Simulationsdaten trainiert ist, wird in diesem Idealszenario eine sehr geringe Abweichung erwartet. Abbildung 6.5 zeigt die simulierte Querbeschleunigung und den vom Schätzalgorithmus prädizierten Querbeschleunigungsverlauf, sowohl vor als auch nach der Iteration des Skalierungsfaktors. Der Skalierungsfaktor der besten Anpassung beträgt $f_s = 1.01$. Dabei liegt er leicht neben dem




Abbildung 6.5: Anwendung des Schätzalgorithmus auf Daten der Fahrdynamiksimulation

zu erwarteten Skalierungsfaktor von $f_s = 1.0$. Die mittlere Fehler beträgt $MAE = 0.27 m/s^2$. Dabei liegt der Fehler im Bereich des Validierungsergebnisses des neuronalen Netzes aus Tabelle 6.3. Das legt die Vermutung nahe, dass durch eine Verbesserung im Training dieser Fehler weiter reduziert werden kann. Das Ergebnis zeigt, dass durch den Algorithmus grundsätzlich eine gute Annäherung der Querbeschleunigung erreicht werden kann.

Wird der Reibwert in der Simulation verändert, verstärkt sich die Skalierung durch den Schätzalgorithmus. In Abbildung 6.6 ist der Reibwert durch die Skalierungsparameter des Pacejka Reifenmodell auf 120% erhöht. Nach der Iteration der Skalierungsfaktoren beträgt der bleibende Fehler der besten Anpassung $MAE = 0.31 m/s^2$. Der Skalierungsfaktor beträgt $f_s = 1.09$, was deutlich vom erwarteten Skalierungsfaktor von $f_s = 1.2$ entfernt ist. Der Grund liegt in den unterschiedlichen Skalierungsmethoden für den maximalen Reibwert durch die Pacejka Reifenmodell und den Schätzalgorithmus. Auf den theoretischen Hintergrund wurde dazu in Abschnitt 2.3.2 eingegangen. Die Ergebnisse aus Abschnitt 5.1.4 lassen darauf schließen, dass das durch den Schätzalgorithmus implementierte Skalierungsverfahren gegenüber der Skalierung durch das Pacejka Reifenmodell eine höhere Robustheit in der Realfahrzeuganwendung besitzt. Durch dieses Beispiel wird die Bedeutung einer realitätsnahen Skalierung der Reifendaten für das Ergebnis der Schätzung erneut ersichtlich. Es ist theoretisch möglich, die Skalierung der Reifendaten in der Fahrdynamiksimulation auf die gleiche Methode wie im Schätzalgorithmus zu ändern, aber für die Bewertung des Algorithmus bietet dies keinen erkennbaren Mehrwert.




Abbildung 6.6: Anwendung des Schätzalgorithmus auf Daten der Fahrdynamiksimulation bei einem eingestellten Reibwert von 120% durch Anpassung der Skalierungsfaktoren der Pacejka Magic Formula

Um den Konflikt der Skalierungsmethoden zwischen Simulation und Algorithmus zu umgehen, wird in Abbildung 6.7 ein Abgleich mit Messdaten aus der Erprobung in Croix-en-Ternois 2019 gezeigt.




Abbildung 6.7: Anwendung des Schätzalgorithmus auf Messdaten des Devbot aus Croix-en-Ternois in 2019

Die Streckenbedingungen waren nass und die Asphalttemperatur deutlich geringer als in Modena oder Montebianco. Dies ist an der starken Skalierung der geschätzten Querbewegung zu erkennen. Nach der Skalierung kann der gemessene Querbewegungsverlauf durch den Schätzalgorithmus gut nachgebildet werden. Der Skalierungsfaktor liegt im dargestellten Messausschnitt bei $f_s = 0.41$. Zusammen mit der maximalen stationären Querbewegung im Geschwindigkeitsbereich von $a_y = 13.1 \text{ m/s}$ ergibt sich ein geschätztes Querbewegungslimit von $a_{y,lim} = 5.4 \text{ m/s}$. Die Ermittlung des wahren Querbewegungslimits ist in der Retrospektive nur eingeschränkt möglich. Aus der Dokumentation des Testtags ist ersichtlich, dass das maximal eingestellte Querbewegungslimit $a_{y,lim} = 4.94 \text{ m/s}$ betrug. Ein höheres Limit führte in einem vorangegangenen Lauf zu einem Abbruch. Im Vergleich dazu konnte der menschliche Fahrer das Fahrzeug in diesem Sektor bis zu einer Querbewegung von $a_y = 5.5 \text{ m/s}$ bewegen bis deutliche Übersteuerreaktionen zu bemerken waren, die eine Gegenreaktion des Fahrers zu Folge hatten. Das geschätzte Querbewegungslimit liegt im Bereich

des empirisch ermittelten Limits und bestätigt damit die Vermutung aus Abschnitt 5.1.4, dass die gewählte Skalierungsmethode für die Anwendung auf reale Fahrzeugdaten geeignet ist.

Der gezeigte Vergleich ist jedoch bestenfalls eine Bestätigung, dass die Schätzung durch den Algorithmus grundsätzlich plausibel ist. Für eine sinnvolle Validierung ist die Aufnahme von Messdaten bei unterschiedlichen Reibwertbedingungen mit Bestimmung der maximalen stationären Querbewegung als Referenz erforderlich. Die vorliegenden Messdaten können dies nicht leisten.

Nicht immer kann der Querbewegungsverlauf so gut nachgebildet werden wie in Abbildung 6.7. Abbildung 6.8 zeigt einen Ausschnitt aus Messdaten der Erprobung in Modena. Der bleibende Fehler nach der Skalierung beträgt $MAE = 0.68 \text{ m/s}^2$ und liegt höher als in




Abbildung 6.8: Anwendung des Schätzalgorithmus auf Messdaten des Devbot aus Modena in 2019

den anderen Beispielen. Die größten Abweichungen zwischen gemessener und geschätzter Querbewegung können beim Aufbau und bei der Reduzierung der Querbewegung beobachtet werden. Die Analyse weiterer Messdaten stützt die Beobachtung, dass in transienten Situationen die reine proportionale Skalierung des Reibwerts nicht ausreicht, um jederzeit eine gute Übereinstimmung zwischen gemessener und geschätzter Querbewegung zu erreichen. Drei Gründe können dafür die Ursache sein:

1. Durch die gewählte Reifenskalierungsmethode wird die Schräglaufsteifigkeit bei Variation des Reibwerts ebenfalls verändert. Das kann nach aktuellem Stand der Wissenschaft als umstritten beschrieben werden. Die referenzierten Quellen aus Abschnitt 2.3.2, die eine Veränderung der Schräglaufsteifigkeit bei einer Veränderung des maximalen Reibwerts beobachtet haben, untersuchten jeweils vergleichsweise große Sprünge des maximalen Reibwerts, wie beispielsweise einen Sprung von festen auf losen Untergrund. Die Autoren, die keinen Zusammenhang zwischen maximalem Reibwert und Schräglaufsteifigkeit feststellen konnten, untersuchten meist kleinere Sprünge im maximalen Reibwert. Es ist daher denkbar, dass je nach Ursache der Reibwertveränderung, die Skalierung der Schräglaufsteifigkeit durch den Schätzalgorithmus mehr oder weniger zutreffend ist. Dadurch können sich im Bereich des Schräglaufwinkelaufbaus größere Abweichungen ergeben als im Grenzbereich, bei dem die Querkraftkurve im Bereich ihrer Sättigung ausgewertet wird und leichte Variationen im Schräglaufwinkel keine großen Querkraftunterschiede mehr bewirken.

2. Das Reifenmodell ist nicht für die Berücksichtigung von transienten Effekten geeignet. Das Anpassen des Pacejka Reifenmodells geschieht auf Basis von Daten aus stationären Tests. Das transiente Reifenverhalten kann dadurch nicht abgebildet werden. In der realen Anwendung kommt es aufgrund der Reifenrelaxationslänge in transienten Situationen zu einer gewissen Verzögerung in der Reifenkraftentwicklung [95].
3. Die Simulations-Anwendung der Giermomentdiagramme kann durch Konvergenz in quasi-stationären Fahrsituationen ebenfalls keine transienten Effekte abbilden, wie in Unterkapitel 4.1 beschrieben. Einflüsse durch Dämpferkräfte werden dadurch vernachlässigt.

6.2.2 Closed-Loop Anwendung des Algorithmus

In der Closed-Loop Anwendung des Schätzungsalgorithmus erfolgt die Rückführung der Querschleunigungslimits in den Trajektorienplanungsalgorithmus. Dazu wird die existierende SiL Umgebung verwendet, die die simultane Ausführung der Module Planning mit integrierter Schätzung der Querschleunigungslimits und Control ermöglicht, die in Abschnitt 5.1.2 bereits beschrieben wurden. Zur Ausführung der SiL Umgebung wurde die Hardware aus Tabelle 6.4 verwendet. Für die Analyse erfolgt die Einteilung in Sektoren der Reibwertkarte anhand fester Sektorenlängen von $l = 50\text{ m}$. In der Frequenz von 10 Hz werden durch das Modul zur Schätzung von Querschleunigungslimits die aktuellen Fahrzustandsdaten abgefragt und eine Prüfung ausgeführt, ob eine Sektorengrenze überfahren wurde. Die Fahrzustandsschätzung wird mit 100 Hz ausgeführt, was bedeutet, dass bei jeder Ausführung des Moduls zehn neue Datensätze aus der Fahrzustandsschätzung verarbeitet werden. Bewegt sich das Fahrzeug noch im identischen Sektor, wird durch das neuronale Netz die Querschleunigungsprädiktion durchgeführt und zusammen mit den bereits erfolgten Prädiktionen und der gemessenen Querschleunigung für denselben Sektor in einem Zwischenspeicher gehalten. Wird eine Sektorgrenze überfahren, kann die Iteration der Skalierungsfaktoren durchgeführt werden. Für den durchfahrenen Sektor wird mit der neuen Schätzung das Limit in der Reibwertkarte aktualisiert. Die Aktualisierung der Reibwerte erfolgt nur lokal gebunden, in dem Sektor des Rundkurses an der die Messdaten entstanden sind. Die Schätzung wird daher erst bei in der Trajektorienplanung der nächsten Runde berücksichtigt.

Tabelle 6.4: Hardwarespezifikation für die SiL-Umgebung

Hardware	Spezifikation
Prozessor	AMD Ryzen 7 3700X 8x3.6 GHz
Arbeitsspeicher	32 GB

Um unplausible Schätzungen abzufangen, wird die Implementierung von Sicherheitsabfragen realisiert. Bei Nichterfüllung der Bedingungen wird, anstatt der Schätzung durch den Algorithmus, ein festes Sicherheits-Querschleunigungslimit $a_{y,lim,safety}$ ausgegeben. Dieses Limit wird manuell vorgegeben und soll so gewählt sein, dass es jederzeit unter denen für den Streckenbedingungen erwartbaren Querschleunigungsgrenzen liegt. Eine Überprüfung erfolgt auf die durchschnittlich gemessene Querschleunigung im Sektor, da die Schätzung auf Geraden oder Streckenabschnitten mit geringer Querschleunigungsanregung ein hohes Rauschen aufweist (Abschnitt 6.2.3). Liegt diese unter dem festgelegten Grenzwert $a_{y,avg,min}$, erfolgt die Umstellung auf die Ausgabe des Sicherheits-Querschleunigungslimits. Eine weitere Überprü-

fung erfolgt auf den bleibenden Fehler nach erfolgter Iteration des Skalierungsfaktors. Liegt der verbleibende Fehler über einem parametrierbaren zulässigen Maximalfehler MAE_{max} , wird das Ergebnis der Schätzung ignoriert und das Sicherheits-Querbeschleunigungslimit $a_{y,lim,safety}$ ausgegeben.

Zusätzlich wird implementiert, dass der resultierende Fehler bei der Berechnung des Querbeschleunigungslimits berücksichtigt werden kann. Bei einer angenommenen Normalverteilung des Fehlers kann durch Gleichung 6.1 eine Schätzung ausgegeben werden, die ein Konfidenzniveau berücksichtigt. Dabei ist $a_{y,lim}$ das geschätzte Querbeschleunigungslimit durch den Schätzungsalgorithmus und die Standardabweichung σ wird durch den resultierenden RMSE der Schätzung gebildet.

$$a_{y,lim,Konfidenz} = a_{y,lim} - f_k \sigma \quad (6.1)$$

Der Zusammenhang zwischen dem Faktor f_k und dem Konfidenzniveau des Querbeschleunigungslimits $a_{y,lim,Konfidenz}$ ist in Tabelle 6.5 gezeigt.

Tabelle 6.5: Konfidenzniveau der Schätzung in Abhängigkeit von f_k

Konfidenzniveau	f_k
50%	0
84,1%	1
97,7%	2
99,8%	3

Abbildung 6.9 visualisiert den Konfidenzbereich. Bei der Anwendung eines Faktor von $f_k = 2$ ist die gemessene Querbeschleunigung zu 97,7% innerhalb des Konfidenzbereichs. Der Algorithmus berücksichtigt durch dieses Vorgehen die Unsicherheit der Schätzung und verhält sich vorsichtiger, wenn der Fehler der Schätzung größer ausfällt.




Abbildung 6.9: Geschätzte Querbeschleunigung nach der Skalierung der Reifendaten im Vergleich zur gemessenen Querbeschleunigung. Der Konfidenzbereich ist dargestellt für ein Konfidenzniveau von 97,7%

Das Ergebnis des Schätzungsalgorithmus über mehrere Runden in der Closed-Loop Anwendung auf der virtuellen Rennstrecke in Modena ist in Abbildung 6.10 gezeigt. Zu sehen sind sowohl das Geschwindigkeitsprofil als auch der Verlauf der Querbeschleunigung und die jeweiligen vom Trajektorienplaner berücksichtigten Querbeschleunigungslimits. Die verwendete Parametrierung ist in Tabelle 6.6 dokumentiert. Das Fahrzeug bewegt sich in der ersten Runde mit festen Querbe-

Tabelle 6.6: Parametrierung des Schätzalgorithmus

Parameter	Wert
$a_{y,lim,safety}$	12 m/s^2
$a_{y,avg,min}$	2 m/s^2
MAE_{max}	0.5 m/s^2
f_k	2




Abbildung 6.10: Anwendung des Schätzalgorithmus in der SiL Umgebung über mehrere Runden. Das Streckenprofil entspricht der Rennstrecke in Modena.

schleunigungslimits von $a_{y,lim} = 6 \text{ m/s}^2$ in einer Explorationsfahrt. Ab der zweiten Runde werden die im Verlauf der ersten Runde gesammelten Querschleunigungslimits vom Trajektorienplaner berücksichtigt. Dabei ist dem Algorithmus möglich auch bei geringerer Anregung direkt das Querschleunigungslimit zu schätzen. Die Unsicherheit der Schätzung wird größer, je stärker durch den Algorithmus extrapoliert werden muss. Das ist durch die größeren Abweichungen in der Querschleunigungsgrenzen in der zweiten Runde zu erkennen, die erst ab der dritten Runde etwas konstanter werden. Das Extrapolationsverhalten wird in Abschnitt 6.2.3 noch genauer untersucht. In Sektoren mit erfolgreichen Sicherheitsüberprüfungen liegt der Mittelwert der Schätzung ab der dritten Runde bei $a_{y,lim} = 12,62 \text{ m/s}^2$ mit einer Standardabweichung von $\sigma = 0,38 \text{ m/s}^2$.




Abbildung 6.11: Vorgabe einer festen Querschleunigungsgrenze von $a_{y,lim} = 12,5 \text{ m/s}^2$ in der SiL Umgebung über mehrere Runden. Das Streckenprofil entspricht der Rennstrecke in Modena.

Im Vergleich ist in Abbildung 6.11 der Verlauf bei einer Vorgabe von festen Querschleunigungslimits von $a_{y,lim} = 12,5 \text{ m/s}^2$ gezeigt. Das Limit wurde empirisch ermittelt und stellt die

Referenz dar. Im Rennbetrieb ist eine solche empirische Ermittlung nicht möglich und aufgrund veränderlichen Bedingungen nicht konstant. Der Geschwindigkeitsverlauf und der Querbe-




Abbildung 6.12: Vergleich der Rundenzeiten. Links: Verwendung der geschätzten Querbeschleunigungslimits Rechts: Verwendung eines festen Querbeschleunigungslimits von $a_{y,lim} = 12,5 \text{ m/s}^2$

schleunigungsverlauf zeigen über die Runden die zu erwartende Konstanz der Simulation. Der Vergleich der Rundenzeiten erfolgt in Abbildung 6.12. Im direkten Vergleich sind die erreichten Rundenzeiten bei Anwendungen des Schätzalgorithmus im Mittel um $0,4 \text{ s}$ langsamer und unterliegen ab der dritten Runde einer Schwankung im Bereich von $\pm 0,2 \text{ s}$. Das ist überraschend, da das durchschnittliche Querbeschleunigungslimit der Schätzung von $a_{y,lim} = 12,62 \text{ m/s}^2$ leicht über dem festen Limit von $a_{y,lim} = 12,5 \text{ m/s}^2$ liegt.

In der Analyse der Rundenzeitunterschiede konnte die Ursache für die langsameren Rundenzeiten bei aktiviertem Schätzalgorithmus gefunden werden. So hat der Algorithmus in Sektoren, in denen das geschätzte Querbeschleunigungslimit unter $a_{y,lim} = 12,5 \text{ m/s}^2$ liegt, Zeit verloren. Jedoch konnte nicht in allen Sektoren, in denen die Schätzung über $a_{y,lim} = 12,5 \text{ m/s}^2$ lag, Zeit gewonnen werden. Teilweise kam es dabei zu größeren Querabweichungen in der Trajektorie, die in der Korrektur zu einem weiteren Zeitverlust führen. Diese Erkenntnis führte zur Einführung eines Modus zur vorsichtigen Exploration. Bei aktiviertem Modus wird die geschätzte Querbeschleunigung im abgeschlossenen Sektor mit der letzten Schätzung des Sektors abgeglichen. Liegt die aktualisierte Schätzung über der Schätzung aus der Runde davor, werden beide Werte gemittelt. Dadurch tastet sich der Algorithmus über mehrere Runden an das Limit heran, anstatt in der ersten Runde nach der Explorationsrunde direkt das geschätzte Querbeschleunigungslimit an den Trajektorienplaner zu geben. Liegt das geschätzte Querbeschleunigungslimit unter dem Limit der letzten Runde, erfolgt die Aktualisierung der Reibwertkarte für den Sektor ohne Mittlung. Die Änderung bewirkt eine vorsichtigeres Vorgehen des Algorithmus und eine Beruhigung der Schätzung im Grenzbereich.

Das Verhalten mit aktiviertem Modus zur vorsichtigen Exploration ist in Abbildung 6.13 gezeigt. Die durchschnittliche Schätzung im eingeschwungenen Zustand steigert sich auf $a_{y,lim} = 12,73 \text{ m/s}^2$ und die Standardabweichung sinkt auf $\sigma = 0,28 \text{ m/s}^2$. Das verbesserte Verhalten des Schätzung führt zur einer Reduktion der Rundenzeit, wie in Abbildung 6.14 gezeigt. Die Untersuchung zeigt, dass durch den Algorithmus zur Schätzung von Querbeschleunigungslimits eine selbstständige Exploration und Ermittlung des Querbeschleunigungslimits möglich ist, die ab der zweiten Runde zur Planung von Trajektorien im Grenzbereich verwendet werden können. Dadurch kann ohne vorherige Kenntnis des Fahrbahn-Reifen-Reibwerts ein Operieren im Grenzbereich ermöglicht werden, was durch die Vorgabe von festen Querbeschleunigungslimits nicht möglich ist. In der Praxis sind die Querbeschleunigungslimits vor Fahrtbeginn nicht




Abbildung 6.13: Anwendung des Schätzalgorithmus mit aktivierten Modus zur vorsichtigen Exploration

bekannt und können sich lokal unterscheiden. Das untersuchte Szenario stellt folglich die ideale Situation mit konstanten Bedingungen dar. Die Tatsache, dass der Algorithmus in der Lage ist, die Rundenzeiten mit empirisch gesetzten Grenzen zu erreichen, deutet darauf hin, dass der Algorithmus einen Rundenzeitvorteil bei variablen Reibwerten erzielen kann. Kann auf das




Abbildung 6.14: Rundenzeiten mit aktivierten Modus zur vorsichtigen Exploration.

direkte Vorstoßen in den Grenzbereich ab der zweiten Runde verzichtet werden zeigt sich, dass durch den Modus zur vorsichtigen Exploration das Risiko von zu hohen Schätzungen reduziert wird. Zusätzlich verringert sich die Rundenzeit nach wenigen Runden durch die reduzierte Streuung der Schätzung.

6.2.3 Untersuchung zur Streuung der Schätzung

Die Qualität der Schätzung in der SiL Umgebung hängt neben einer geeigneten Parametrierung besonders von der Anregungsintensität und der Sektorlänge ab. Da die Umgebungsbedingungen in der Simulation jederzeit konstant sind, ist der zu erwartende Skalierungsfaktor durch den Schätzalgorithmus $f_S = 1$.

Streuung in Abhängigkeit der Anregungsintensität

Je geringer das fest vorgegebene Querschleunigungslimit auf der Explorationsrunde, desto stärker die notwendige Extrapolation durch den Schätzalgorithmus. In Abbildung 6.15 ist

die Auswirkung auf die geschätzten Skalierungsfaktoren der Sektoren in der Explorationsrunde in Abhängigkeit des vorgegebenen Querbeschleunigungslimits gezeigt. Dabei ist ersichtlich,




Abbildung 6.15: Boxplot Darstellung zur Streuung der Schätzung in Abhängigkeit der Anregungsintensität.

dass die Streuung mit der Erhöhung der Initialquerbeschleunigung kontinuierlich abnimmt. Bei einer Anregungsquerbeschleunigung von $a_{y,lim} = 4 \text{ m/s}^2$ liegen einzelne Schätzungen mit einem Skalierungsfaktor von $f_s = 1.13$ deutlich über dem zu erwartenden Wert von $f_s = 1$. Ab einem Querbeschleunigungslimit von $a_{y,lim} = 10 \text{ m/s}^2$ liegt die Streuung zwischen dem 25. und 75. Perzentil in einem akzeptablen Bereich zwischen $f_s = 1.0$ und $f_s = 1.02$. Die Nutzung der Untersuchungsergebnisse zur Reduzierung des Risikos von Schätzungen oberhalb der wahren Querbeschleunigungsgrenze bei starker Extrapolation durch den Algorithmus erscheint für die zukünftige Weiterentwicklung denkbar.

Streuung in Abhängigkeit der Sektorlänge

Im vorangegangenen Abschnitt 6.2.2 erfolgte die Aufteilung in Sektoren durch feste Sektorlängen von $l = 50 \text{ m}$. Die in Abschnitt 5.1.5 beschriebene variable Aufteilung der Sektoren war zum Abschluss der Arbeit noch nicht voll umfänglich verfügbar und wurde im Rahmen der Arbeit in eine Aufteilung mit festen Sektorlängen reduziert. Daher wird der Einfluss der festen Sektorlänge untersucht. Abbildung 6.16 zeigt die Streuung des Skalierungsfaktors auf der Explorationsrunde




Abbildung 6.16: Boxplot Darstellung zur Streuung der Schätzung in Abhängigkeit der Sektorlänge.

bei einem festen Querbeschleunigungslimit von $a_{y,lim} = 10 \text{ m/s}^2$. Mit Ausnahme der Sektorlänge von $l = 7 \text{ m}$ zeigt sich eine abnehmende Streuung bei einer Erhöhung der der Sektorlänge.

Ebenso liegt bei kurzen Sektoren der Median des Skalierungsfaktors bei $f_s = 1.03$ und rückt erst durch die Vergrößerung der Sektorlänge bis auf den Median von $f_s = 1.01$ und damit näher an den zu erwarteten Skalierungsfaktor von $f_s = 1.0$.

Die Ergebnisse zeigen einen Zielkonflikt. Auf der einen Seite führen längere Sektoren zu einer präziseren Schätzung, wodurch die Rundenzeit und das Risiko einer zu hohen Schätzung reduziert wird. Auf der anderen Seite führt die Aufteilung in längere Sektoren dazu, dass lokale Reibwertunterschiede nicht berücksichtigt werden können. Es bleibt zu überprüfen, ob die variable Aufteilung der Sektoren einen positiven Einfluss auf die Streuung der Skalierungsfaktoren besitzt. Die Ergebnisse von Abschnitt 6.2.1 deuten darauf hin, dass eine Anwendung, die auf Sektoren mit stationären Kurven beschränkt ist, die Streuung deutlich reduzieren kann.

7 Diskussion

In der Arbeit kann eine modulare Anwendung zur Erstellung von Giermomentdiagrammen für die Fahrdynamikanalyse und Parameterstudien vorgestellt werden. Die Anwendung ist leicht an bestehende Simulationsumgebungen adaptierbar und liefert tiefe Einblicke in der Fahrzeugverhalten. Eine weitere Diskussion erfolgt in Unterkapitel 7.1.

Aufbauend auf der Querschleunigungsprädiktion der Giermomentdiagramme konnte ein neuartiger, echtzeitfähiger, modellbasierter Schätzalgorithmus für Querschleunigungslimits vorgestellt werden. Die Stärken und Schwächen des Ansatzes, sowie die Gründe für Notwendigkeit weiterer Untersuchungen werden in Unterkapitel 7.2 diskutiert.

7.1 Erstellung und Analyse von Giermomentdiagrammen

In der Arbeit konnte die Milliken Moment Method zur Erstellung von Giermomentdiagrammen erfolgreich implementiert werden. Dabei wird auf bestehenden Fahrdynamikmodellen aufgebaut, die ohne weitere Modifikation als Black Box in das Modell integriert werden können. Dadurch hebt sich die Implementierung ab von kommerziellen Tools zur Erstellung von Giermomentdiagrammen, wie das der *Milliken Research Associates Inc.* [96] oder anderen Implementierungen durch *Ratschiller* [83] und *Hofmann et al.* [37]. In der modernen Fahrzeugentwicklung ist ein detailliertes Fahrdynamikmodell oftmals vorhanden, sodass eine Anwendung, die das bestehende Modell inklusive Parametrierung direkt verwenden kann, für eine einfache Integration und konsistente Ergebnisse sorgt. Die Implementierung in Matlab/Simulink und in Python bietet Schnittstellen in zwei, weit verbreiteten Entwicklungsumgebungen.

Die verwendete Reglerstruktur zeigt durch die Maßnahmen in Unterkapitel 4.1 ein stabiles Konvergenzverhalten der Simulation. Bei größeren Parameteränderungen des Fahrdynamikmodells muss die Parametrierung der Reglerstruktur überprüft werden, um in instabilen Fahrsituationen ein Aufschwingen der Regler zu verhindern.

Vor dem Abschluss der Arbeit wurde die Matlab/Simulink Implementierung bereits vom Formula Student Team *DHBW Engineering e.V.* adaptiert. Die Anpassungen der Parametrierung der Reglerstruktur, proportional zur Änderung der relevanten Fahrzeugparameter, wie Rotationsträgheit und Fahrzeugmasse, reichten bereits für ein gutes Konvergenzverhalten der Simulation aus. Der Implementierungsaufwand belief sich auf wenige Stunden und konnte bereits den Vorteil des modularen Aufbaus belegen.

Ein besonderer Schwerpunkt der Implementierung liegt darin, dass nicht nur einzelne Giermomentendiagramme betrachtet werden, sondern das Fahrzeugverhalten über den Geschwindigkeitsbereich in Kombination mit unterschiedlichen Längsbeschleunigungen. Dadurch wird der Einfluss der Längsmomente am Reifen und der Achslastverteilung in Bezug auf das Fahr-

verhalten berücksichtigt. Bei der Analyse von Parametervariationen können die Auswirkungen innerhalb des Manöverraums differenziert betrachtet und Kompromisse aufgedeckt werden.

Im Postprocessing werden die Giermomentdiagramme und weitere Diagramme mit abgeleiteten Größen zur Stabilität und Kontrolle erstellt, die eine Quantifizierung des Fahrzeugverhaltens ermöglichen und den Ingenieur im Applikationsprozess und beim Verständnis des Fahrzeugverhaltens unterstützen. Zusätzlich wird die Ableitung von KPIs durchgeführt, die eine vereinfachte Vergleichbarkeit bei Parametervariationen ermöglichen. Durch die Modularität der Anwendung ist eine Betrachtung aller Parameter des Fahrdynamikmodells möglich. Auch können verschiedene Fahrdynamikmodelle miteinander verglichen werden, um herauszufinden, wie sich die Modelle im Ergebnis unterscheiden.

Eine exemplarische Parametervariation in Unterkapitel 4.4 auf der Basis des nichtlinearen Zweispurmodells führt zu plausiblen Ergebnissen, die zum Teil zu erwarten sind und zum Teil zu neuen, unerwarteten Erkenntnissen führen. So führt beispielsweise eine Verbreiterung der Spurweite zu einer erwarteten Erhöhung der maximalen Querschleunigung. Für die untersuchte Fahrzeugkonfiguration blieb die maximale stationär erreichbare Querschleunigung jedoch unverändert und konnte nur durch eine weitere Modifikation der Fahrzeugbalance erhöht werden. Hervorzuheben ist der Einfluss der Antriebsmomentverteilung, die eine hohe Sensitivität auf die Ergebnisse aufweist. Da die Antriebsmomentverteilung im verwendeten Zweispurmodell noch nicht berücksichtigt wird, wird eine Implementierung empfohlen.

Die Stabilitäts- und Kontrollableitungen, die sich aus den Giermomentendiagrammen ableiten lassen, können ebenfalls einen Mehrwert bei der Analyse des Fahrzeugverhaltens liefern. Ein Vergleich mit Messdaten zeigt eine gute Korrelation mit dem beobachtbaren Fahrzeugverhalten. Mit den Ableitungen lässt sich zum Beispiel erklären, warum ein neutral abgestimmtes Fahrzeug theoretisch das höchste Querschleunigungspotenzial bietet, ein Fahrzeug ohne Reserven aber insbesondere bei Lastwechselszenarien instabil wird. Jede notwendige Korrektur durch den Fahrer kostet Zeit und bestätigt damit die empirischen Erkenntnisse im Motorsport, dass ein Setup mit einem Fahrzeug, das im Grenzbereich leicht über die Vorderachse schiebt, oftmals die schnellste Rundenzeit erreicht.

Die Korrelation der Ergebnisse der Giermomentendiagramme mit Messdaten wird für die beiden Ausgangsgrößen Querschleunigung und Giermoment differenziert betrachtet. Die Korrelation der Querschleunigung zeigt eine gute qualitative Korrelation, was für eine hohe Modellvalidität spricht. Abweichungen zwischen gemessener Querschleunigung und der durch die Anwendung des Giermomentendiagramms simulierten Querschleunigung sind in der Regel proportional konstant und legen die Vermutung nahe, dass ein lokal abweichender Reibwert die Ursache ist. Die Beobachtungen liefern die Grundidee für den Algorithmus zur echtzeitfähigen Schätzung der Querschleunigungslimits im zweiten Teil der Arbeit.

Eine Korrelation des Giermoments konnte nicht erfolgreich untersucht werden. Zur Rückberechnung des Giermoments aus der gemessenen Ableitung der Gierrate ist die Kenntnis der Gierdämpfung erforderlich. Diese verhält sich nichtlinear und müsste mit zusätzlichen Unsicherheiten abgeleitet werden. Aufgrund des geringen Zusatznutzens der Untersuchung wird die Korrelation des Giermoments nicht weiter untersucht.

7.2 Echtzeitfähige Schätzung der Querbeschleunigungslimits

In dieser Arbeit wird ein neuartiger, modellbasierter Algorithmus zur Schätzung von Querbeschleunigungslimits für die Echtzeitanwendung in Trajektorienplanungsalgorithmen vorgestellt.

Durch die Vorabsimulation von hochaufgelösten Giermomentdiagrammen kann ein nichtlineares Zweispurmodell verwendet werden, um für eine Vielzahl an Fahrsituationen die Referenz-Querbeschleunigung zu ermitteln. Die Ergebnisse können von einem neuronalen Netz im Live-Fahrzeugbetrieb regressiert werden, was den Rechenaufwand deutlich reduziert und die Echtzeitfähigkeit gewährleistet. Um den Querbeschleunigungsfehler zwischen Vorhersage durch das neuronale Netz und der gemessenen Querbeschleunigung zu minimieren, wird das Reifenmodell iterativ skaliert. Der resultierende Skalierungsfaktor des kleinsten Querbeschleunigungsfehlers führt, zusammen mit der Kenntnis der maximalen stationären Querbeschleunigung aus dem Post-Processing der Giermomentendiagramme, zu einer Schätzung des Querbeschleunigungslimits.

Das Potential der Methode kann durch die Ergebnisse der Arbeit aufgezeigt werden. Insbesondere die Ausgabe eines Querbeschleunigungslimits anstelle eines maximalen Reibwerts ist für die Anwendung in Trajektorienplanungsalgorithmen interessant, da sie die direkte Verwendung bei der Berechnung von Geschwindigkeitsprofilen ermöglicht. Ebenso können bei der Erstellung von Reibwertkarten durch Einteilung einer Strecke in Sektoren sowohl örtliche, wie zeitliche Reibwertdifferenzen berücksichtigt und zur Rundenzeitminimierung genutzt werden. Ein weiterer Vorteil ist die Kenntnis des stationären Querbeschleunigungslimits durch das Postprocessing der Giermomentendiagramm-Anwendung, wodurch die Schätzung des Fahrzeugsetup berücksichtigt. Die Herausforderung in der Entwicklung des Algorithmus liegt in der realistischen Skalierung des Reifenmodells.

Um den Regressionsalgorithmus für die Prädiktion der Querbeschleunigung auszuwählen, wurde ein Vergleich von vier verschiedenen ML-Algorithmen durchgeführt. Das MLP erzielte den besten Kompromiss zwischen Prädiktionsqualität und Rechengeschwindigkeit.

Das Training des neuronalen Netzes wurde auf den Einfluss verschiedener Hyperparameter untersucht und es wurde eine Trainingspipeline erstellt, die für die Anwendung angepasste Netze trainieren kann. Es kann gezeigt werden, dass das neuronale Netz unter Verwendung der Eingangsgrößen Geschwindigkeit v , Längsbeschleunigung a_x , Schwimmwinkel β und Lenkwinkel δ in der Lage ist, den Querbeschleunigungsverlauf der Rundkurssimulation mit einem nicht-linearen Zweispurmodell in hoher Genauigkeit nachzubilden.

Die Herausforderung der vorgestellten Methode zur Schätzung von Querbeschleunigungslimits liegt in der realistischen Skalierung des Reifenverhaltens bei variierenden Reibwerten infolge wechselnder Umgebungsbedingungen.

Bereits im Stand der Technik wird gezeigt, dass ein variierender Reibwert zu unterschiedlichen Änderungen des qualitativen Reifenverhaltens führt. Dies führt zu der Annahme, dass die qualitative Veränderung des Reifenverhaltens abhängig von der Ursache der Reibwertveränderung ist. Da die Ursache der Reibwertänderung nicht a priori bekannt ist, resultiert daraus, dass es keine allgemeingültige Methode zur Skalierung des Reifenverhaltens geben kann. Streng genommen ist das Reifenmodell, das durch die Pacejka-Formel angepasst wird, immer nur für den Reibwert gültig, bei dem die Reifendaten aufgezeichnet wurden.

Ein Vergleich von zwei Skalierungsmethoden mit Daten von verschiedenen Rennstrecken und Witterungsbedingungen zeigt, dass durch die Skalierung der Ausgangswerte des Pacejka-Reifenmodells eine durchschnittlich bessere Anpassung erreicht werden kann als durch die Verwendung der internen Reibwertskalierungsfaktoren der Pacejka-Formel. Die Ergebnisse führen damit zu dem Schluss, dass die Skalierung der Ausgangswerte des Pacejka-Reifenmodells im Durchschnitt die Vielfalt der möglichen Ursachen für die Änderung des Reibungskoeffizienten besser abdecken kann.

Eine Überprüfung des Algorithmus mit gemessenen Daten zeigt, dass die Schätzungen des Algorithmus grundsätzlich mit den Grenzwerten der Querbeschleunigung übereinstimmen, die sich aus der Versuchsdokumentation und der Analyse des Fahrzeugverhaltens ergeben.

Eine Überprüfung des Algorithmus in der SiL-Umgebung führt zu proportionalen Abweichungen der Schätzung zum erwartenden Wert. Der Grund dafür sind die unterschiedlichen Reifenskalierungsmethoden, die in der Fahrdynamiksimulation und im Schätzalgorithmus verwendet werden. Dies verdeutlicht die Bedeutung einer realistischen Skalierung des Reifenverhaltens. Um zu überprüfen, ob der Algorithmus in der realen Anwendung zu validen Schätzungen kommt, ist die Validierung mit Messdaten notwendig, bei denen die Querbeschleunigungslimit bekannt ist. Eine Vielzahl verschiedener Parameter mit Einfluss auf den Reibwert müssen variiert werden, um die Robustheit des Verfahrens zu überprüfen.

Mithilfe der Giermomentdiagramm-Anwendung ist eine Erhebung von Reifendaten ohne eine Verwendung eines stationären oder fahrbaren Reifenprüfstand denkbar, wie bereits durch *Milliken et al.* vorgeschlagen [18]. Durch eine Rückwärtsanpassung des Reifenmodells durch die Giermomentdiagramme ist die flexible Aufnahme von Reifendaten bei verschiedensten Reibwertbedingungen möglich. Dadurch kann die weitergehende Untersuchung der Problematik ermöglicht werden.

Die Implementierung des Algorithmus in der Closed-Loop SiL-Umgebung führt zur notwendigen Einführung verschiedener Sicherheitsprüfungen und Mechanismen zum Abfangen von zu hohen Schätzungen des Limits, um ungewollte Abflüge des Fahrzeugs zu verhindern. Bei entsprechender Parametrierung ist ein sicherer Betrieb des Fahrzeugs möglich. Es können unter Verwendung des Schätzalgorithmus Rundenzeiten erreicht werden, die im Bereich von Rundenzeiten mit empirisch gesetzten, festen Querbeschleunigungsgrenzen liegen.

Teilweise kam es in der SiL-Simulation zu einer Beobachtung von ungewollten Fahrzeugreaktionen, wie einem Eindrehen des Fahrzeugs. Die Analyse zeigt, dass trotz einer Schätzung unter dem möglichen Querbeschleunigungslimit instabile Fahrsituationen auftreten, die durch den Fahrzeugregler nicht abgefangen werden können. Die Auswertung der Stabilitätsableitung der Giermomentdiagramme zeigt, dass ein Operieren im instabilen Bereich und nicht eine zu hohe Schätzung des Querbeschleunigungslimits Auslöser für die Abflüge war. Diese Erkenntnis eröffnet neue Fragestellungen, wie eine solche Situation im Rennbetrieb erfolgreich gelöst werden kann. Mögliche Ansätze sind die Berücksichtigung und Vermeidung von instabilen Fahrsituationen in der Trajektorienplanung oder eine Untersuchung, inwieweit ein Kompromiss zwischen Bahnfolgeregelung und Fahrzeugstabilität durch den Fahrzeugregler des Control-Blocks gefunden werden kann.

Eine Untersuchung zur Streuung der Schätzung erfolgt in Abhängigkeit der Sektorlänge und der Initialquerbeschleunigung. Dabei ist erkenntlich, dass eine geringere Initialquerbeschleunigung mit einer höheren Streuung einhergeht. Um Schätzungen über dem wahren Limit zu vermeiden, kann die Kenntnis über das Maß der Streuung berücksichtigt werden.

Die Untersuchung der Streuung in Abhängigkeit der Sektorlänge zeigt einen Zielkonflikt auf. Auf der einen Seite führen längere Sektoren zu einer präziseren Schätzung, wodurch die Rundenzeit und das Risiko einer zu hohen Schätzung reduziert wird. Auf der anderen Seite führt die Aufteilung in längere Sektoren dazu, dass lokale Reibwertunterschiede nicht berücksichtigt werden können. Ob eine dynamische Aufteilung der Sektoren anhand des Fahrzustands den erwarteten positiven Einfluss auf die Präzision der Schätzung bietet, konnte bisher nicht überprüft werden. Die bisherigen Ergebnisse lassen vermuten, dass in Sektoren mit stationärer Kurvenfahrt die Genauigkeit der Schätzung am größten ist, da das Reifenmodell und die Giermomentdiagramm-Anwendung transiente Effekte nur eingeschränkt abbilden können.

8 Zusammenfassung und Ausblick

In der Arbeit ist eine Anwendung zur Erstellung von Giermomentdiagrammen durch die Milliken Moment Method für die Umgebung Matlab/Simulink und Python entstanden. Die Modularität der Implementierung ermöglicht eine einfache Substitution des verwendeten Fahrdynamikmodells und ist Basis für eine Open-Source Verwendbarkeit.

Ein Postprocessing zur automatisierten Ableitung von Diagrammen und KPI unterstützen den Ingenieur im Verständnis über das Fahrzeugverhalten und zeigen die Kompromisse von Setup-änderungen über das gesamte fahrdynamische Spektrum des Fahrzeugs. Die Giermomentendiagramme sind eine Quelle von Informationen zur Manövrierfähigkeit, Stabilität und Kontrolle. Die Anwendung eignet sich für allgemeine Modellstudien und für Parameterstudien.

Eine Untersuchung der Korrelation der Ergebnisse der Giermomentendiagramme mit Messdaten liefert für mehrere untersuchte Aspekte durchweg gute Ergebnisse. Im Einzelfall hängt dies naturgemäß von der Validität des verwendeten Fahrdynamikmodells ab.

Die Verwendung der Giermomentendiagramme zur Ableitung einer Referenzquerbeschleunigung liefert den Ansatz für einen neuartigen, modellbasierten Algorithmus zur Schätzung von Querbeschleunigungslimits. Durch eine iterative Skalierung des Reifenmodells wird der Querbeschleunigungsfehler zwischen Messdaten und Prädiktion minimiert und zusammen mit der Kenntnis der maximalen stationären Querbeschleunigung aus den Referenz-Giermomentendiagrammen ein Querbeschleunigungslimit geschätzt. Der Ansatz unterscheidet sich in zwei Punkten grundlegend von bestehenden Algorithmen zur Reibwertschätzung.

1. Als Ausgangsgröße wird anstelle des Reibwerts ein Querbeschleunigungslimit angegeben. Für gängige Trajektorienplanungsalgorithmen ist die Kenntnis über das Querbeschleunigungslimit relevant für die Generierung von Geschwindigkeitsprofilen. Durch die Verwendung der Referenzquerbeschleunigung aus den Giermomentendiagrammen werden durch diesen Ansatz fahrzeugspezifische Eigenschaften bei der Umrechnung des Reibwerts in eine maximal mögliche Querbeschleunigung berücksichtigt.
2. Durch die Vorsimulation von hochauflösenden Giermomentendiagrammen kann die Vorhersage der Referenz-Querbeschleunigung im Fahrzeugbetrieb durch ein mit den Simulationsdaten trainiertes neuronales Netz erfolgen. Dadurch werden die Vorteile eines modellbasierten Ansatzes mit einem detaillierten nichtlinearen Zweispurmodell mit dem geringen Rechenaufwand eines datenbasierten Ansatzes kombiniert und führen zur Echtzeitfähigkeit des Algorithmus.

In einer Closed-Loop Simulation kann der Schätzalgorithmus zusammen mit mehreren Sicherheitsmechanismen ein sicheres Operieren des Fahrzeugs im Grenzbereich ermöglichen. Die erreichbaren Rundenzeiten liegen im Bereich von fest vorgegebenen, empirisch ermittelten Querbeschleunigungslimits.

Zur Validität der Schätzung in der realen Anwendung können durch die Arbeit erste Indizien gesammelt werden, die auf eine plausible Schätzungen durch den Algorithmus hinweisen. Die Ergebnisse verdeutlichen jedoch auch, dass das Schätzungsergebnis abhängig von der verwendeten Methode zur Skalierung des Reifenmodells abhängig ist. Damit eine realistische und robuste Vorgehensweise zur Anpassung des Reifenmodells an die aktuelle Reibwertsituation gefunden werden kann, sind weitere Untersuchungen mit realen Fahrzeugmessdaten erforderlich, für die das Querschleunigungslimit bekannt ist.

Die Arbeit stellt eine umfassende Anwendung zur Erzeugung von Giermomentdiagrammen zur Verfügung, durch die das Fahrzeugverständnis erhöht und eine Unterstützung im Applikationsprozess gegeben werden kann. Der auf dieser Basis entwickelte Algorithmus zur Schätzung von Querschleunigungslimits zeigt zwar Potenzial, es ist aber offensichtlich, dass für eine sichere und zuverlässige Anwendung des Algorithmus weitere Untersuchungen notwendig sind. Die Arbeit liefert mehrere Ansatzpunkte für die weitere Validierung, Entwicklung und Verwendung der Ergebnisse:

- Zur Validierung des Schätzalgorithmus ist die Aufnahme von Messdaten bei verschiedenen Reibwertbedingungen erforderlich, zu denen das Querschleunigungslimit bekannt ist.
- Der Schätzalgorithmus kann um die Streckenneigung als weitere Eingangsgröße erweitert werden. Besonders für die Anwendung auf Ovalkursen ist die Streckenneigung eine relevante Einflussgröße auf das Ergebnis.
- Die Giermomentdiagramme bieten durch Rückwärtsanpassung die Möglichkeit zur Erhebung von Reifendaten, ohne die Verwendung eines stationären oder mobilen Prüfstands. Das eröffnet die Möglichkeit, Reifendaten bei verschiedenen Umgebungsbedingungen aufzunehmen, um das Verhalten bei veränderlichen Reibwerten zu untersuchen.
- Die Arbeit zeigt die Problemstellung auf, dass es trotz Operation innerhalb der Beschleunigungsgrenzen zu einer Überschreitung der Stabilitätsgrenzen des Fahrzeug kommen kann. Das eröffnet die Fragestellung, inwiefern Kompromisse zwischen Bahnfolgeregelung und Stabilität des Fahrzeugs getroffen werden müssen, um ein sicheres Operieren am Limit zu ermöglichen.

Abbildungsverzeichnis

Abbildung 1.1:	Indy Autonomous Challenge Fahrzeug	1
Abbildung 2.1:	Modellparameter im Einspurmodell	4
Abbildung 2.2:	Zweispurmodell mit Modellparametern	5
Abbildung 2.3:	Einfluss der Koeffizienten auf die Pacejka Magic Formula.....	9
Abbildung 2.4:	Theoretischer Aufbau der Milliken Moment Method.....	10
Abbildung 2.5:	Giermomentdiagramm mit konstanter Geschwindigkeit	12
Abbildung 2.6:	Verlauf einer Kurve im Giermomentdiagramm.....	13
Abbildung 2.7:	Charakteristische Punkte im Giermomentdiagramm.....	14
Abbildung 2.8:	Adhäsionsreibung und Hysteresereibung	18
Abbildung 2.9:	F_y - α Diagramm der Reifen des Devbot	19
Abbildung 2.10:	Einfluss des maximalen Reibwerts auf die Querkraftkurve von drei ver- schiedensten Reifenmodellen.....	21
Abbildung 2.11:	Devbot TUM Autonomous Racing Team	24
Abbildung 2.12:	Einordnung von Regression Algorithmen im Bereich der Artificial Intelli- gence	25
Abbildung 2.13:	Nearest Neighbour veranschaulicht	26
Abbildung 2.14:	Lineare Regression veranschaulicht.....	27
Abbildung 2.15:	Aufbau eines Neuron.....	28
Abbildung 2.16:	Vergleich verschiedener Aktivierungsfunktionen.....	29
Abbildung 2.17:	Aufbau des Multi Layer Perceptron	29
Abbildung 2.18:	Überanpassung und Unteranpassung im Trainingsprozess	30
Abbildung 3.1:	Blockschaubild Modell für die Milliken Moment Method	35
Abbildung 3.2:	Vergleich des gemessenen mit dem simulierten Torque Vectoring Gier- moment.....	37
Abbildung 3.3:	Kräfte am Fahrzeug in einer Kurve mit Fahrbahneigung	38
Abbildung 3.4:	Zeitverlauf der Referenzwerte mit PT1 Verzögerungsglied	39
Abbildung 3.5:	Parallelisierte Simulation mithilfe des <i>Process Pool Executors</i>	40
Abbildung 3.6:	Beispielhaftes Giermomentdiagramm auf Basis des nichtlinearen Zwei- spurmodell.....	41
Abbildung 3.7:	Bereinigung der Giermomentdiagramme zur Verbesserung der Über- sichtlichkeit	42
Abbildung 3.8:	Überlagerung der Umrandung von Giermomentdiagrammen bei verschie- denen Geschwindigkeiten	42
Abbildung 4.1:	Konvergenzverhalten der Simulation	46
Abbildung 4.2:	Einfluss der Geschwindigkeit v und Längsbeschleunigung a_x auf die Giermomentdiagramme	47
Abbildung 4.3:	Stabilität, Kontrolle und Dämpfung innerhalb des Manöverraums	49
Abbildung 4.4:	Durchfahren einer Kurve mit der Scandinavian Flick Technik.....	50
Abbildung 4.5:	Vergleich des Einlenkverhaltens in eine Kurve mit und ohne die Anwen- dung des Scandinavian Flick	51

Abbildung 4.6:	Einfluss verschiedener Parameteränderungen auf die maximale stationär erreichbare Querbeschleunigung	52
Abbildung 4.7:	Einfluss verschiedener Parameteränderungen auf die maximale Querbeschleunigung	52
Abbildung 4.8:	Einfluss verschiedener Parameteränderungen auf das resultierende Giermoment am Punkt der maximalen Querbeschleunigung	53
Abbildung 4.9:	Einfluss verschiedener Parameteränderungen auf die Stabilitätsableitung im Punkt der maximalen stationären Querbeschleunigung	53
Abbildung 4.10:	Einfluss verschiedener Parameteränderungen auf die Kontrollableitung im Punkt der maximalen stationären Querbeschleunigung	54
Abbildung 4.11:	Einfluss verschiedener Parameteränderungen auf das maximale Giermoment.....	54
Abbildung 4.12:	Vergleich der gemessenen Querbeschleunigung des Devbots mit der nachsimulierten Querbeschleunigung.....	55
Abbildung 4.13:	Vergleich des berechneten Giermoments aus Messdaten des Devbots mit dem nachsimulierten Giermoment	56
Abbildung 4.14:	Überlagerung der Messdaten des Devbots aus Monteblanco 2019 mit den Stabilitäts- und Kontrollableitungen	57
Abbildung 5.1:	Nachsimulation der gemessenen Querbeschleunigung	60
Abbildung 5.2:	Strukturdiagramm des Algorithmus zur Schätzung von Querbeschleunigungslimits	61
Abbildung 5.3:	Vergleich des Regressionsverhalten der verschiedenen ML Algorithmen..	64
Abbildung 5.4:	Vergleich der Reifenskalierungsmethoden.....	65
Abbildung 5.5:	Annäherung von niedrigen Reibwerten durch die Skalierungsmethoden...	66
Abbildung 5.6:	Aufbau von Reibwertkarten.....	68
Abbildung 5.7:	Trainingsablauf für das Training von Machine Learning Algorithmen	68
Abbildung 5.8:	Unterteilung der Datensätze bei einer 5-fold Cross Validation.....	70
Abbildung 5.9:	Auswirkung des Penaltyterms α auf die Generalisierungsfähigkeit des Netzes	70
Abbildung 6.1:	Boxplot Diagramm zu den Trainingsergebnissen bei einer Variation der L2 Regularisierung	72
Abbildung 6.2:	Boxplot Diagramm zu den Trainingsergebnissen für unterschiedliche Netzgrößen.....	73
Abbildung 6.3:	Boxplot Diagramm zu den Trainingsergebnissen in Abhängigkeit von der durchschnittlichen Netzwerkbreite.....	73
Abbildung 6.4:	Boxplot Diagramm zu den Trainingsergebnissen in Abhängigkeit von der Netzwerktiefe	73
Abbildung 6.5:	Anwendung des Schätzungsalgorithmus auf Daten der Fahrdynamiksimulation	75
Abbildung 6.6:	Anwendung des Schätzungsalgorithmus auf Daten der Fahrdynamiksimulation mit einem Reibwert von 120%	76
Abbildung 6.7:	Anwendung des Schätzungsalgorithmus auf Messdaten des Devbot aus Croix-en-Ternois in 2019	76
Abbildung 6.8:	Anwendung des Schätzungsalgorithmus auf Messdaten des Devbot aus Modena in 2019.....	77
Abbildung 6.9:	Konfidenzbereich der Schätzung	79
Abbildung 6.10:	Anwendung des Schätzungsalgorithmus in der SiL Umgebung über mehrere Runden.....	80

Abbildung 6.11: Vorgabe einer festen Querschleunigungsgrenze in der SiL Umgebung .	80
Abbildung 6.12: Vergleich der Rundenzeiten	81
Abbildung 6.13: Anwendung des Schätzungsalgorithmus mit aktivierten Modus zur vorsichtigen Exploration	82
Abbildung 6.14: Rundenzeiten mit aktivierten Modus zur vorsichtigen Exploration.....	82
Abbildung 6.15: Boxplot Darstellung zur Streuung der Schätzung in Abhängigkeit der Anregungsintensität.....	83
Abbildung 6.16: Boxplot Darstellung zur Streuung der Schätzung in Abhängigkeit der Sektorlänge.	83

Tabellenverzeichnis

Tabelle 2.1:	Die wichtigsten Eingangs- und Ausgangsgrößen des verwendeten Einspurmodells	5
Tabelle 2.2:	Die wichtigsten Eingangs- und Ausgangsgrößen des verwendeten Zweispurmodells	7
Tabelle 3.1:	Verwendung der Eingangsmerkmale in der Simulation.....	36
Tabelle 3.2:	Berechnete KPI im Postprocessing	41
Tabelle 5.1:	Wertebereich der Eingangsmerkmale für die Simulation.....	62
Tabelle 5.2:	Leistungsfähigkeit der Regressionsalgorithmen im Vergleich.....	64
Tabelle 5.3:	Vergleich der Skalierungsmethoden in verschiedenen Ausschnitten aus Messdaten des Devbots. Der MAE- und R^2 -Wert der besten Anpassung für beide Methoden mit resultierendem Skalierungsfaktor f_S ist aufgeführt...	66
Tabelle 5.4:	Durchschnittliche Leistungsfähigkeit der Skalierungsmethoden im Vergleich	67
Tabelle 6.1:	Wertebereich für den Parametersuchraum der Random Search	71
Tabelle 6.2:	Ergebnisse der verschiedenen Aktivierungsfunktionen im Vergleich	71
Tabelle 6.3:	Trainingsergebnisse bei Training mit und ohne Cross Validation. Im Fall mit Cross Validation ist das Validierungsergebnis gemittelt über alle Iterationen. Im Fall der vollständigen Verwendung der Trainingsdaten ist das Validierungsergebnis gleich dem Trainingsverlust der letzten Epoche	74
Tabelle 6.4:	Hardwarespezifikation für die SiL-Umgebung	78
Tabelle 6.5:	Konfidenzniveau der Schätzung in Abhängigkeit von f_k	79
Tabelle 6.6:	Parametrierung des Schätzungsalgorithmus	80

Literaturverzeichnis

- [1] F. Pfeil, *Megatrends und die dritte Revolution der Automobilindustrie: Eine Analyse der Transformation der automobilen Wertschöpfung auf Basis des Diamantmodells*, (Research papers on marketing strategy). Bd. no. 13 (2018), Würzburg, Lehrstuhl für BWL und Marketing Julius-Maximilians-Universität Würzburg, 2018, ISBN: 978-3-00-059102-0. Verfügbar: <http://hdl.handle.net/10419/175349>.
- [2] SAE International. „J3016: Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems,“ 2021. [Online]. Verfügbar: https://www.sae.org/standards/content/j3016_201806/ [aufgerufen am 13.06.2021].
- [3] D. J. Fagnant und K. Kockelman, „Preparing a nation for autonomous vehicles: opportunities, barriers and policy recommendations,“ *Transportation Research Part A: Policy and Practice*, Bd. 77, S. 167–181, 2015, DOI: 10.1016/j.tra.2015.04.003.
- [4] A. Faisal, T. Yigitcanlar, M. Kamruzzaman und G. Currie, „Understanding autonomous vehicles: A systematic literature review on capability, impact, planning and policy,“ *Journal of Transport and Land Use*, Bd. 12, Rn. 1, 2019, DOI: 10.5198/jtlu.2019.1405.
- [5] R. Kannan und R. C. Lasky, „Autonomous Vehicles Still Decades Away: 2019,“ in *2020 Pan Pacific Microelectronics Symposium (Pan Pacific)*, HI, USA, 10.02.2020 - 13.02.2020, S. 1–6, ISBN: 978-1-944543-14-3. DOI: 10.23919/PanPacific48324.2020.9059394.
- [6] Y. Wiseman und I. Grinberg, „Circumspectly crash of autonomous vehicles,“ in *2016 IEEE International Conference on Electro Information Technology (EIT)*, Grand Forks, ND, USA, 19.05.2016 - 21.05.2016, S. 0387–0392, ISBN: 978-1-4673-9985-2. DOI: 10.1109/EIT.2016.7535271.
- [7] Y. Qin, E. Hashemi und K. Amir, „Integrated Crash Avoidance and Mitigation Algorithm for Autonomous Vehicles,“ *IEEE Transactions on Industrial Informatics*, S. 1, 2021, DOI: 10.1109/TII.2021.3058948.
- [8] K. Lee und D. Kum, „Collision Avoidance/Mitigation System: Motion Planning of Autonomous Vehicle via Predictive Occupancy Map,“ *IEEE Access*, Bd. 7, S. 52846–52857, 2019, DOI: 10.1109/ACCESS.2019.2912067.
- [9] motorline.cc. „Das erste fahrerlose Autorennen steht an,“ 2021. [Online]. Verfügbar: <https://www.motorline.cc/motorsport/news/2021/Last-but-not-least/Indy-Autonomous-Challenge-Countdown-1%C3%A4uft-Das-erste-fahrerlose-Autorennen-steht-an-237823.html> [aufgerufen am 20.03.2021].
- [10] Energy Systems Network. „Indy Autonomous Challenge Rules: v5NOV2019 (2),“ 2021. [Online]. Verfügbar: <https://static1.squarespace.com/static/5da73021d0636f4ec706fa0a/t/5dc0680c41954d4ef41ec2b2/1572890638793/Indy+Autonomous+Challenge+Rulesest+-+v5NOV2019+%28%29.pdf> [aufgerufen am 17.03.2021].

- [11] Hexagon. „Datasheet Aptiv ESR 2.5: Aptiv Electronically Scanning RADAR,“ 2021. [Online]. Verfügbar: <https://hexagondownloads.blob.core.windows.net/public/AutonomousStuff/wp-content/uploads/2020/10/aptiv-esr-25-24v-datasheet.pdf> [aufgerufen am 17.03.2021].
- [12] Energy Systems Network, „IAC-DO12 Vehicle: Vehicle Specification Sheet,“ Indianapolis, 2021.
- [13] W. F. Milliken, P. G. Wright und D. L. Milliken, „Moment Method - A Comprehensive Tool for Race Car Development,“ in *SAE Technical Paper Series*, 1994, DOI: 10.4271/942538.
- [14] W. F. Milliken und D. L. Milliken, *Race car vehicle dynamics*, (SAE R). Bd. 146, 14. print, Warrendale, Pa., Society of Automotive Engineers, 1995, ISBN: 9781560915263.
- [15] D. Kang, J. L. Stein, R. C. Hofmann, L. S. Louca und K. Huh, Hrsg. „*Implementing the Milliken Moment Method using Controlled Dynamic Simulation*,“ (Detroit, Michigan). Bd. 1916. SAE-SP. SAE International und Society of Automotive Engineers, 2005. ISBN: 0-7680-1561-8.
- [16] S. Khaleghian, A. Emami und S. Taheri, „A technical survey on tire-road friction estimation,“ *Friction*, Bd. 5, Rn. 2, S. 123–146, 2017, DOI: 10.1007/s40544-017-0151-0.
- [17] M. Acosta, S. Kanarachos und M. Blundell, „Road Friction Virtual Sensing: A Review of Estimation Techniques with Emphasis on Low Excitation Approaches,“ *Applied Sciences*, Bd. 7, Rn. 12, S. 1230, 2017, DOI: 10.3390/app7121230.
- [18] William F. Milliken, Peter G. Wright und Douglas L. Milliken, „Moment Method - A Comprehensive Tool for Race Car Development,“ *Motorsports Engineering Conference & Exposition*, 1994, DOI: 10.4271/942538.
- [19] H. B. Pacejka, *Tyre and vehicle dynamics*, 2.ed., Amsterdam, Elsevier, 2006, ISBN: 0-7506-6918-7.
- [20] P. Riekert und T. E. Schunck, „Zur Fahrmechanik des gummibereiften Kraftfahrzeugs,“ *Ingenieur-Archiv*, Bd. 11, Rn. 3, S. 210–224, 1940, DOI: 10.1007/BF02086921.
- [21] D. Schramm, M. Hiller und R. Bardini, *Modellbildung und Simulation der Dynamik von Kraftfahrzeugen*, 2., vollst. überarb. Aufl., Berlin, Springer Vieweg, 2013, ISBN: 978-3-642-33887-8.
- [22] M. Mitschke und H. Wallentowitz, *Dynamik der Kraftfahrzeuge*, Wiesbaden, Springer Fachmedien Wiesbaden, 2014, ISBN: 978-3-658-05067-2. DOI: 10.1007/978-3-658-05068-9.
- [23] M. Guiggiani, *The Science of Vehicle Dynamics*, Dordrecht, Springer Netherlands, 2014, ISBN: 978-94-017-8532-7. DOI: 10.1007/978-94-017-8533-4.
- [24] P. Pfeffer und M. Harrer, *Lenkungs-handbuch*, Wiesbaden, Springer Fachmedien Wiesbaden, 2013, ISBN: 978-3-658-00976-2. DOI: 10.1007/978-3-658-00977-9.
- [25] T. Wongpattananukul und C. Chantharasanawong, „Effect of suspension kinematic on 14 DOF vehicle model,“ *IOP Conference Series: Materials Science and Engineering*, Bd. 272, S. 012018, 2017, DOI: 10.1088/1757-899X/272/1/012018.
- [26] W. Schindler, „Umsetzung eines detaillierten Fahrdynamik-Modells in Matlab/Simulink für die Simulation eines autonomen Rennfahrzeugs,“ Masterarbeit, Lehrstuhl für Fahrzeugtechnik, Technische Universität München, München, 2019.

- [27] R. Pütz und T. Serné, *Rennwagentechnik - Praxislehrgang Fahrdynamik: Eine praktische Anleitung für Amateure und Profis*, (Handbuch Rennwagentechnik). Bd. / Reihenherausgeber Michael Trzesniowski, Wiesbaden, Springer Vieweg, 2017, ISBN: 978-3-658-16101-9. Verfügbar: <http://www.springer.com/de/book/978-3-658-16101-9>.
- [28] B. Knauder, D. Savitski, J. Theunissen und L. de Novellis, „Electric torque vectoring for electric vehicles,“ *ATZelektronik worldwide*, Bd. 9, Rn. 4, S. 50–55, 2014, DOI: 10.1365/s38314-014-0268-0.
- [29] M. Trzesniowski, *Rennwagentechnik: Grundlagen, Konstruktion, Komponenten, Systeme*, (ATZ/MTZ-Fachbuch), 4., überarb. und erw. Aufl., Wiesbaden, Springer Vieweg, 2014, ISBN: 978-3-658-04918-8.
- [30] R. Isermann, *Fahrdynamik-Regelung: Modellbildung, Fahrerassistenzsysteme, Mechatronik ; mit 28 Tabellen*, (ATZ/MTZ-Fachbuch), Wiesbaden, Vieweg, 2006, ISBN: 978-3-8348-0109-8. Verfügbar: http://deposit.dnb.de/cgi-bin/dokserv?id=2684377&prov=M&dok_var=1&dok_ext=htm.
- [31] DIN ISO 8855:2013-11, Straßenfahrzeuge_- Fahrzeugdynamik und Fahrverhalten_- Begriffe (ISO_8855:2011).
- [32] A. Ortiz, J. A. Cabrera, A. J. Guerra und A. Simon, „An easy procedure to determine Magic Formula parameters: a comparative study between the starting value optimization technique and the IMM optimization algorithm,“ *Vehicle System Dynamics*, Bd. 44, Rn. 9, S. 689–718, 2006, DOI: 10.1080/00423110600574558.
- [33] Dr. Michael Gipser, „Reifenmodelle in der Fahrzeugdynamik: eine einfache Formel genügt nicht mehr, auch wenn sie magisch ist,“ *MKS-Simulation in der Automobilindustrie*, Bd. 2001, 2001. Verfügbar: https://www.cosin.eu/wp-content/uploads/ftire_germ_1.pdf [aufgerufen am 15.03.2021].
- [34] Claude Rouelle, „The four secrets for chassis happiness,“ *Racecar Engineering*, Rn. November, S. 58–60, 2017.
- [35] C. D. Perkins und R. E. Hage, *Airplane performance stability and control*, New York, Wiley, 1949, ISBN: ,978-0-471-68046-8.
- [36] J. Pauwelussen, *Essentials of Vehicle Dynamics*, Burlington, Elsevier Science, 2014, ISBN: 978-0-08-100036-6. Verfügbar: <http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=877237>.
- [37] R. C. Hoffman, J. L. Stein, L. S. Louca und K. Huh, Hrsg. „Using the Milliken Moment Method and dynamic simulation to evaluate vehicle stability and controllability VEHICLE STABILITY AND CONTROLLABILITY,“ (Anaheim, California USA). 2004. Verfügbar: <http://proceedings.asmedigitalcollection.asme.org/>.
- [38] Shoji Inagaki, Ikuo Kshiro, M. Yamamoto, „Analysis on vehicle stability in critical cornering using phase-plane method Shoji Inagaki, Ikuo Kshiro, Masaki Yamamoto (Toyota Motor Corp./Japan), pp. 287–292, 14 figs., 4 refs,“ *JSAE Review*, Bd. 16, Rn. 2, S. 216, 1995, DOI: 10.1016/0389-4304(95)94930-1.
- [39] J. Yi, J. Li, J. Lu und Z. Liu, „On the Stability and Agility of Aggressive Vehicle Maneuvers: A Pendulum-Turn Maneuver Example,“ *IEEE Transactions on Control Systems Technology*, Bd. 20, Rn. 3, S. 663–676, 2012, DOI: 10.1109/TCST.2011.2121908.

- [40] J. C. Kegelmann, „Learning from professional race car drivers to make automated vehicles safer,“ Dissertation, Department of Mechanical Engineering, Stanford University, Stanford, California, United States of America, 2018. Verfügbar: <http://purl.stanford.edu/jh569zw7186>.
- [41] H. W. Kummer, *Unified theory of rubber and tire friction*, (Technical Report), Pennsylvania, 1966.
- [42] B. Heißing, M. Ersoy und S. Gies, *Fahrwerkhandbuch: Grundlagen, Fahrdynamik, Komponenten, Systeme, Mechatronik, Perspektiven ; mit 84 Tabellen*, (Aus dem Programm Kraftfahrzeugtechnik), Wiesbaden, Vieweg + Teubner, 2011, ISBN: 978-3-8348-0821-9.
- [43] T. C. Hüsemann, *Adaption von Labor-Reifenkennfeldern an reale Fahrbahnoberflächen*, (IKA-Schriftenreihe Automobiltechnik). Bd. 148, Aachen, Forschungsges. Kraftfahrwesen (fka), 2011, ISBN: 9783940374516.
- [44] J. Holtschulze, „Analyse der Reifenverformung für eine Identifikation des Reibwerts und weiterer Betriebsgrößen zur Unterstützung von Fahrdynamikregelsystemen,“ Dissertation, RWTH Aachen, 2006.
- [45] Société de Technologie Michelin, *The Tire Grip*, Clermont-Ferrand, Société de Technologie Michelin, 2001.
- [46] C. Lex, „Maximum tire-road friction coefficient estimation,“ 2015, ISBN: 9783851254235. DOI: 10.3217/978-3-85125-422-8.
- [47] T. Bachmann, *Literaturrecherche zum Reibwert zwischen Reifen und Fahrbahn*, (Berichte aus dem Fachgebiet Fahrzeugtechnik der TH Darmstadt). Bd. 286, Als Ms. gedr, Düsseldorf, VDI-Verl., 1996, ISBN: 9783183286126.
- [48] G. Leister, *Fahrzeugreifen und Fahrwerkentwicklung: Strategie, Methoden, Tools*, (Praxis ATZ-MTZ Fachbuch), 1. Aufl., Wiesbaden, Vieweg + Teubner, 2009, ISBN: 978-3-8348-0671-0.
- [49] C. R. Carlson und J. C. Gerdes, „Consistent nonlinear estimation of longitudinal tire stiffness and effective radius,“ *IEEE Transactions on Control Systems Technology*, Bd. 13, Rn. 6, S. 1010–1020, 2005, DOI: 10.1109/TCST.2005.857408.
- [50] A. Andrieux, P. O. Vandanjon, R. Lengelle und C. Chabanon, „New results on the relation between tyre–road longitudinal stiffness and maximum available grip for motor car,“ *Vehicle System Dynamics*, Bd. 48, Rn. 12, S. 1511–1533, 2010, DOI: 10.1080/00423111003770421.
- [51] A. Albinsson, F. Bruzelius, B. Jacobson und J. Fredriksson, „Design of tyre force excitation for tyre–road friction estimation,“ *Vehicle System Dynamics*, Bd. 55, Rn. 2, S. 208–230, 2017, DOI: 10.1080/00423114.2016.1251598.
- [52] A. M. Ribeiro, A. Moutinho, A. R. Fioravanti und E. C. d. Paiva, „Estimation of Tire-Road Friction for Road Vehicles: a Time Delay Neural Network Approach,“ 01.08.2019. Verfügbar: <http://arxiv.org/pdf/1908.00452v2>.
- [53] Cornelia Lex, *Maximum Tire-Road Friction Coefficient Estimation // Maximum tire-road friction coefficient estimation*, (Reihe Fahrzeugtechnik). Bd. Band 5, 2015, ISBN: 978-3-85125-422-8.
- [54] S. Koskinen und P. Peussa, „Friction: Final Report,“ Tampere, Finland, 2009.
- [55] F. Gustafsson, „Slip-based tire-road friction estimation,“ *Automatica*, Bd. 33, Rn. 6, S. 1087–1099, 1997, DOI: 10.1016/S0005-1098(97)00003-4.

- [56] T. Hsiao, N.-C. Liu und S.-Y. Chen, „Robust estimation of the friction forces generated by each tire of a vehicle,“ in *Proceedings of the 2011 American Control Conference*, San Francisco, CA, 29.06.2011 - 01.07.2011, S. 5261–5266, ISBN: 978-1-4577-0081-1. DOI: 10.1109/acc.2011.5991219.
- [57] N. M’Sirdi, A. Rabhi, A Elhajjaji, Hrsg. „*Estimation of Contac Forces and Tire Road Friction*,“ (Athens, Greece). June 2007.
- [58] K. Li, J. A. Misener und K. Hedrick, „On-board road condition monitoring system using slip-based tyre-road friction estimation and wheel speed signal analysis,“ *Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-body Dynamics*, Bd. 221, Rn. 1, S. 129–146, 2007, DOI: 10.1243/1464419JMBD60.
- [59] H. Fischlein, R. Gnadler und H.-J. Unrau, „The influence of the track surface structure on the frictional force behaviour of passenger car tyres in dry and wet track surface conditions,“ *ATZ worldwide*, Bd. 103, Rn. 10, S. 20–24, 2001, DOI: 10.1007/bf03224516.
- [60] S. Müller, M. Uchanski und K. Hedrick, „Estimation of the Maximum Tire-Road Friction Coefficient,“ *Journal of Dynamic Systems, Measurement, and Control*, Bd. 125, Rn. 4, S. 607–617, 2003, DOI: 10.1115/1.1636773.
- [61] R. Wang, G. Yin und J. Wang, „Vehicle Lateral Velocity and Tire-Road Friction Coefficient Estimation,“ in *Volume 3: Renewable Energy Systems; Robotics; Robust Control; Single Track Vehicle Dynamics and Control; Stochastic Models, Control and Algorithms in Robotics; Structure Dynamics and Smart Structures*; Fort Lauderdale, Florida, USA, Wednesday 17 October 2012, S. 495–502, ISBN: 978-0-7918-4531-8. DOI: 10.1115/DSCC2012-MOVIC2012-8575.
- [62] M. Choi, J. J. Oh und S. B. Choi, „Linearized Recursive Least Squares Methods for Real-Time Identification of Tire–Road Friction Coefficient,“ *IEEE Transactions on Vehicular Technology*, Bd. 62, Rn. 7, S. 2906–2918, 2013, DOI: 10.1109/TVT.2013.2260190.
- [63] R. Wang, C. Hu, Z. Wang, F. Yan und N. Chen, „Integrated optimal dynamics control of 4WD4WS electric ground vehicle with tire-road frictional coefficient estimation,“ *Mechanical Systems and Signal Processing*, Bd. 60-61, S. 727–741, 2015, DOI: 10.1016/j.ymssp.2014.12.026.
- [64] T. Song, H. Zhou und H. Liu, „Road friction coefficient estimation based on BP neural network,“ in *2017 36th Chinese Control Conference (CCC)*, Dalian, China, 26.07.2017 - 28.07.2017, S. 9491–9496, ISBN: 978-988-15639-3-4. DOI: 10.23919/ChiCC.2017.8028871.
- [65] M. Acosta und S. Kanarachos, „Tire lateral force estimation and grip potential identification using Neural Networks, Extended Kalman Filter, and Recursive Least Squares,“ *Neural Computing and Applications*, Bd. 30, Rn. 11, S. 3445–3465, 2018, DOI: 10.1007/s00521-017-2932-9.
- [66] S. Breuer und A. Rohrbach-Kerl, *Fahrzeugdynamik: Mechanik des bewegten Fahrzeugs*, (ATZ / MTZ-Fachbuch), Wiesbaden, Springer Vieweg, 2015, ISBN: 978-3-658-09474-4.
- [67] I.-C. Han, B.-C. Luan und F.-C. Hsieh, „Development of Autonomous Emergency Braking control system based on road friction,“ in *2014 IEEE International Conference on Automation Science and Engineering (CASE)*, Taipei, 18.08.2014 - 22.08.2014, S. 933–937, ISBN: 978-1-4799-5283-0. DOI: 10.1109/coase.2014.6899438.

- [68] K. B. Singh, M. A. Arat und S. Taheri, „Enhancement of Collision Mitigation Braking System Performance Through Real-Time Estimation of Tire-road Friction Coefficient by Means of Smart Tires,“ *SAE International Journal of Passenger Cars - Electronic and Electrical Systems*, Bd. 5, Rn. 2, S. 607–624, 2012, DOI: 10.4271/2012-01-2014.
- [69] Institute of Automotive Technology. „Devbot,“ 2021. [Online]. Verfügbar: <https://www.mw.tum.de/en/ftm/main-research/intelligent-vehicle-systems/roborace-autonomous-motorsport/> [aufgerufen am 24. 03. 2021].
- [70] A. Heilmeier, A. Wischnewski, L. Hermansdorfer, J. Betz, M. Lienkamp und B. Lohmann, „Minimum curvature trajectory planning and control for an autonomous race car,“ *Vehicle System Dynamics*, Bd. 58, Rn. 10, S. 1497–1527, 2020, DOI: 10.1080/00423114.2019.1631455.
- [71] G. Rejala, A. Ravi und S. Churiwala, *An introduction to machine learning*, Cham, Springer, 2019, ISBN: 978-3-030-15728-9.
- [72] Nils J. Nilsson. „Introduction to Machine Learning,“ 2021. [Online]. Verfügbar: <https://ai.stanford.edu/~nilsson/mlbook.html> [aufgerufen am 03. 04. 2021].
- [73] A. V. Joshi, *Machine learning and artificial intelligence*, Cham, Switzerland, Springer, 2020, ISBN: 978-3-030-26621-9.
- [74] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel und P. Prettenhofer. „User Guide,“ 2021. [Online]. Verfügbar: https://scikit-learn.org/stable/user_guide.html [aufgerufen am 04. 04. 2021].
- [75] S. Richter, *Statistisches und maschinelles Lernen: Gängige Verfahren im Überblick*, (Lehrbuch), Berlin, Springer Spektrum, 2019, ISBN: 978-3-662-59353-0.
- [76] Frank Rosenblatt, „The Perceptron - a perceiving and recognizing automation,“ Cornell Aeronautical Laboratory, 1957.
- [77] Rainer Trauth, „Substitution eines Einspurmodells durch maschinelles Lernen zur Fahrdynamiksimulation eines autonomen Rennfahrzeugs,“ Masterarbeit, Fakultät für Maschinenwesen, Technische Universität München, München, 2020.
- [78] K.-L. Du und M. N. S. Swamy, *Neural Networks and Statistical Learning*, London und s.l., Springer London, 2014, ISBN: 978-1-4471-5571-3. DOI: 10.1007/978-1-4471-5571-3.
- [79] D. P. Kingma und J. Ba, „Adam: A Method for Stochastic Optimization,“ 22.12.2014. Verfügbar: <http://arxiv.org/pdf/1412.6980v9>.
- [80] OlexSys. „Data/Parameter Ratio: Have you got enough data for your parameters?,“ 2021. [Online]. Verfügbar: <https://www.olexsys.org/images/overfitting.png> [aufgerufen am 23. 05. 2021].
- [81] Python Software Foundation. „Python 3.9.4 Documentation: The Python Standard Library: Concurrent Execution,“ 2021. [Online]. Verfügbar: [Python%20Software%20Foundation](https://docs.python.org/3.9/library/concurrent.html) [aufgerufen am 24. 04. 2021].
- [82] W. Schneider und B. Heinrich, *Praktische Regelungstechnik: Effektiv lernen durch Beispiele*, (Lehrbuch), 4., überarbeitete Auflage, Wiesbaden, Springer Vieweg, 2017, ISBN: 978-3-658-16992-3.
- [83] J. Ratschiller, „Analyse der Auswirkungen der Gierratenregelung auf das Fahrverhalten eines Formula Student Fahrzeuges anhand eines Giermomentendiagramms,“ Bachelorarbeit, Lehrstuhl für Fahrzeugtechnik, Technische Universität München, München, Deutschland, 2019.

- [84] gamespressure.com. „Driving basics, tips and controls in DiRT Rally 2.0,“ 2021. [Online]. Verfügbar: <https://guides.gamepressure.com/dirt-rally-20/guide.asp?ID=49095> [aufgerufen am 15.05.2021].
- [85] Pedro Figueiredo. „Bild-für-Bild Analyse: Scandinavian Flick im Rallyesport,“ 2021. [Online]. Verfügbar: <https://www.youtube.com/watch?v=UZoZ8GGTR70> [aufgerufen am 15.05.2021].
- [86] J. Betz, A. Wischnewski, A. Heilmeier, F. Nobis, T. Stahl, L. Hermansdorfer und M. Lienkamp, „A Software Architecture for an Autonomous Racecar,“ in *2019 IEEE 89th Vehicular Technology Conference (VTC2019-Spring)*, Kuala Lumpur, Malaysia, 28.04.2019 - 01.05.2019, S. 1–6, ISBN: 978-1-7281-1217-6. DOI: 10.1109/VTCSpring.2019.8746367.
- [87] NumPy Project. „NumPy Documentation,“ 2021. [Online]. Verfügbar: <https://numpy.org> [aufgerufen am 01.05.2021].
- [88] R. Akerkar, *Artificial Intelligence for Business*, (SpringerBriefs in Business), Cham, Springer International Publishing, 2019, ISBN: 978-3-319-97435-4. DOI: 10.1007/978-3-319-97436-1.
- [89] J. Bergstra und Y. Bengio, Hrsg. „*Random Search for Hyper-Parameter Optimization*,“ Journal of Machine Learning Research. 2012.
- [90] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel und P. Prettenhofer. „Cross-validation: evaluating estimator performance,“ 2021. [Online]. Verfügbar: https://scikit-learn.org/stable/_images/grid_search_cross_validation.png [aufgerufen am 25.05.2021].
- [91] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel und P. Prettenhofer. „Varying regularization in Multi-layer Perceptron,“ 2021. [Online]. Verfügbar: https://scikit-learn.org/stable/auto_examples/neural_networks/plot_mlp_alpha.html [aufgerufen am 24.05.2021].
- [92] Jason Brownlee. „Why Initialize a Neural Network with Random Weights?,“ 2021. [Online]. Verfügbar: <https://machinelearningmastery.com/why-initialize-a-neural-network-with-random-weights/> [aufgerufen am 24.05.2021].
- [93] Daniel Godoy. „Hyper-parameters in Action! Part II — Weight Initializers,“ 2021. [Online]. Verfügbar: <https://towardsdatascience.com/hyper-parameters-in-action-part-ii-weight-initializers-35aee1a28404> [aufgerufen am 24.05.2021].
- [94] Y. B. Xavier Glorot, Hrsg. „*Understanding the difficulty of training deep feedforward neural networks*,“ 2010.
- [95] T. Wei und H. R. Dorfi, „Tire Transient Lateral Force Generation: Characterization and Contribution to Vehicle Handling Performance,“ *Tire Science and Technology*, Bd. 42, Rn. 4, S. 263–289, 2014, DOI: 10.2346/tire.14.420402.
- [96] Milliken Research Associates Inc. „MMM Tour: SOLUTION,“ 2021. [Online]. Verfügbar: <https://www.millikenresearch.com/mmmsolution.html> [aufgerufen am 30.05.2021].

