

Laterale Trajektorienprädiktion für Motorräder

Dissertation

zur Erlangung des akademischen Grades

Doktoringenieur

(Dr.-Ing.)

von M.Sc. Karl Ludwig Stolle

geb. am 02.05.1996 in Leipzig

genehmigt durch die Fakultät für Maschinenbau
der Otto-von-Guericke-Universität Magdeburg

Gutachter:

Prof. Dr. Stephan Schmidt

Univ.Prof. Dipl.-Ing. Dr.techn. Johannes Edelmann

Promotionskolloquium am 25.02.2025

Kurzfassung

Motorradfahrer gehören zu den vulnerablen Verkehrsteilnehmern und erfahren zu einem vielfach höheren Risiko Unfälle mit schweren oder tödlichen Verletzungen. Es werden deshalb aktive Sicherheitssysteme für Motorräder entwickelt, um das Auftreten von Unfällen zu vermeiden. Damit zukünftige Systeme in zusätzlichen Fahrsituationen warnen oder rechtzeitig eingreifen können, benötigen diese eine Prädiktion der Fahrt, im Allgemeinen ausgedrückt durch die zukünftige Positionstrajektorie. Bestehende physikalische Modelle der Trajektorienprädiktion gehen nicht auf die Eigenheiten des Zweirads ein und erreichen besonders in Kurvenfahrt Vorausschauzeiten von nur 1 s bis maximal 2 s.

Die besondere Querdynamik des Zweirads motiviert die Erforschung von motorradspezifischen Modellen der Trajektorienprädiktion. Ein Versuchsmotorrad wird ausgestattet, um bisher nicht verwendete Messgrößen der Lenk-Zustandsgrößen, der Lenkmoment-Fahrereingabe und des Fahrerverhaltens in Oberkörperposition und Kopfdrehung zu erfassen. Nach der Untersuchung des querdynamischen Übertragungs- und Fahrerverhaltens anhand von Fahrversuchen wird ein geringes Potenzial motorradspezifischer physikalischer Prädiktionsmodelle festgestellt. Stattdessen wird ein manöverbasierter Prädiktionsansatz verfolgt, welcher mittels der Methode des maschinellen Lernens Informationen zur Fahrerabsicht aus der Zeithistorie von Fahrdynamiksignalen und der neuen Signale der Lenkung und des Fahrerverhaltens interpretiert. Basierend auf einem 74 h und 21 Fahrer umfassenden, selbst erhobenen Fahrdatensatz wird ein auf LSTM-Zellen (Long Short-Term Memory) basierendes neuronales Netz entwickelt. Indem dieses eine Rollwinkeltrajektorie über einen 4 s langen Prädiktionshorizont vorhersagt, wird gezielt nur die laterale Komponente der Trajektorienprädiktion adressiert. Die Transformation in eine Positionstrajektorie erfolgt unter der Annahme konstanter Geschwindigkeit.

Die manöverbasierte laterale Trajektorienprädiktion erreicht in 98,6 % der Testsituationen mindestens 2 s Vorausschauzeit. Gegenüber der Standard-Prädiktion konstanter Kurvenfahrt wird die Anzahl der Situationen mit weniger als 2 s Vorausschau um 89 % reduziert. Die Bedeutung der neuartigen Messgrößen der Lenkung und des Fahrerverhaltens für die Prädiktionsgüte wird in Ablationsstudien untersucht. Wenn sie nicht zur Verfügung stehen, steigt der laterale Positionsfehler um 11,6 %. Rund die Hälfte des positiven Effekts geht vom Lenkmomentsignal aus, welches die Prädiktion in der ersten Sekunde verbessert. Bis zur Prädiktionszeit von 1,5 s und 3 s haben die Oberkörperposition und der Kopfdrehwinkel positiven Einfluss. Die Forschung an motorradspezifischer Trajektorienprädiktion führt zu neuen Erkenntnissen bzgl. Fahrereingaben und -verhalten in Kurvenfahrt und schafft die Grundlagen für die Entwicklung zukünftiger Assistenz- und Sicherheitssysteme im Motorrad.

Abstract

Motorcycle riders belong to the group of vulnerable road users as they are in high risk of heavy injury or fatality in case of accidents. The development of active safety systems for motorcycles aims to prevent these from occurring. Such systems need a predictive element, generally a trajectory prediction, to warn or intervene properly in critical riding situations. State-of-the-art physical trajectory prediction models do not account for the unique characteristics of two-wheelers and thus achieve look-ahead times of only 1 to max. 2 seconds, especially in cornering.

The special lateral dynamics of two-wheelers motivates research on motorcycle-specific algorithms for trajectory prediction. A test motorcycle is being equipped to measure steering state variables, the steering torque rider input, and signals of rider behaviour in upper body position and head rotation – all these signals are not used in existing systems. After investigating the motorcycles' transfer behaviour and rider behaviour based on specific lateral dynamic test manoeuvres, motorcycle-specific physical models for trajectory prediction are assessed low potential. Instead, a manoeuvre-based prediction approach is pursued, that uses machine learning methods to interpret information on rider intention from the time history of riding dynamic as well as the new steering and rider behaviour signals. A neural network comprising LSTM cells (long short-term memory) is developed based on a self-collected data set containing 74 hours of open road riding and 21 riders. It purposely addresses only the lateral component of trajectory prediction by forecasting a roll angle trajectory over a prediction horizon of 4 seconds. This is transformed into a trajectory of future relative positions assuming constant longitudinal velocity of the motorcycle.

The manoeuvre-based lateral trajectory prediction achieves at least 2 seconds look-ahead time in 98.6 % of the test situations. Compared to the standard trajectory prediction that assumes constant cornering, the number of predictions with less than 2 seconds look-ahead time is reduced by 89 %. The importance of the new steering and rider behaviour measurements for the prediction quality is investigated in ablation studies. The lateral position error increases by 11.6 % if all of them are not available. About half of the positive effect comes from the steering torque signal, that strongly improves the prediction in the first second. The upper body position improves trajectory prediction up to a prediction time of 1.5 seconds, the head rotation angle even up to 3 seconds. This research on motorcycle-specific lateral trajectory prediction provides new insights concerning rider inputs and behaviour in cornering and lays the foundation for the development of future motorcycle assistance and safety systems.

Inhaltsverzeichnis

Kurzfassung	I
Abstract	III
Inhaltsverzeichnis	V
Abbildungsverzeichnis	IX
Tabellenverzeichnis	XV
Liste der verwendeten Abkürzungen und Symbole	XVII
1 Einleitung	1
1.1 Motivation	1
1.2 Aktive Motorradsicherheitssysteme	3
1.3 Problemstellung.....	5
1.4 Zielstellung und Vorgehen	6
2 Stand der Forschung	9
2.1 Fahrereingaben und -verhalten in Querdynamik.....	9
2.2 Trajektorienprädiktion.....	16
3 Grundlagen	23
3.1 Zweiraddynamik.....	23
3.1.1 Kinematik und Kippverhalten	23
3.1.2 Dynamikmodelle	26
3.1.3 Lenkdynamik.....	27
3.1.4 Problematik der Simulation.....	30
3.2 Neuronale Netze für Zeitreihendaten	31
3.2.1 Künstliche Neuronen und Zellen	31
3.2.2 Long Short-Term Memory Zelle und Schicht.....	33

3.2.3	Training	35
4	Versuchsmotorrad	39
4.1	Basismotorrad.....	39
4.2	Messgrößen im Lenksystem.....	41
4.3	Fahrerpositionserfassung.....	45
4.3.1	Messmethoden.....	45
4.3.2	Kamerabasierte Oberkörperpositionserfassung	47
4.3.3	Beispielmessung und Messgenauigkeit.....	49
4.4	Messung der Kopfdrehung	51
5	Identifikation des querdynamischen Übertragungsverhaltens	53
5.1	Stationäre Kurvenfahrt	53
5.2	Transiente Kurvenfahrt.....	57
5.2.1	Einführung in die Slalomauswertung.....	57
5.2.2	Fahrerbewegung im Slalom	59
5.2.3	Übertragungsverhalten des Lenkmoments im Slalom	60
5.2.4	Fahrerbewegung im Spurwechsel	63
5.2.5	Physische Betrachtung der Fahrerbewegung	64
5.3	Schlussfolgerung	66
6	Datenerhebung zum Realfahrverhalten	69
6.1	Zielsetzung und Durchführung.....	69
6.2	Manöversegmentierung	71
6.2.1	Konzept querdynamischer Manöversegmente	71
6.2.2	Realisierung mit Zustandsautomat	74
6.2.3	Charakteristik der Fahrdaten	77
6.3	Fahrweise und Fahrstil im Datensatz	78
6.4	Korrelation von Kopfdrehung und Kurventrajektorie.....	83
7	Manöverbasierte laterale Trajektorienprädiktion	89
7.1	Ansatz.....	89

7.2	Metriken	91
7.3	Modellarchitektur & Datenaufbereitung	95
7.4	Optimierung des Prädiktionsmodells	99
7.5	Standardbewegungsmodell als Benchmark	105
8	Ergebnisse der lateralen Trajektorienprädiktion	107
8.1	Verbesserung gegenüber Standardbewegungsmodell	108
8.2	Manöverspezifisches Verhalten der Prädiktion	109
8.3	Fahrerspezifisches Verhalten der Prädiktion	112
8.4	Bedeutung der neuartigen Messgrößen	117
8.4.1	Effekt der Signalgruppen der Lenk- und Fahrerhaltensgrößen	117
8.4.2	Einzeleffekte der Lenkgrößen	119
8.4.3	Einzeleffekte der Fahrerhaltensgrößen	123
8.5	Einfluss der Längsdynamik	127
8.6	Beantwortung der Forschungsfragen & Diskussion	129
9	Zusammenfassung & Ausblick	135
	Literaturverzeichnis	141
	Publikationsliste	147
	Anhang	i
A.1	Unfallgeschehen des Motorrads in Europa	i
A.2	Analytische Berechnungen zur DMS-Auslegung	ii
A.3	Algorithmus zur Bestimmung der Fahrerposition aus Markerpositionen	iv
A.4	Vorfragebogen der Datenerhebung zum Realfahrverhalten	vi
A.5	Zustandsautomat zur Klassifikation querdynamischer Manöversegmente	ix
A.6	Korrektur fehlerhaft klassifizierter Manöversegmente	xi
A.7	Konstante Parameter der Hyperparameteroptimierungen	xiv
A.8	Rollwinkel- und Positionsprädiktion in einem Beispielmanöver	xv
A.9	Manöversegmente im Testdatensatz nach Geschwindigkeitsbereichen	xvii

Abbildungsverzeichnis

Abbildung 1.1: Drei Gruppen aktiver Motorradsicherheitssysteme mit Beispielfunktionen. Bereits in Serie erhältliche Funktionen sind hervorgehoben.	3
Abbildung 2.1: Schematische Darstellung typischer Fahrstile der Oberkörperbewegung auf dem Motorrad. Die Skizzen zeigen jeweils eine Rückansicht von Fahrer und Fahrzeug.	13
Abbildung 3.1: Definition von horizontiertem und fahrzeugfestem Fahrzeugkoordinatensystem sowie Lenkkoordinatensystem entsprechend DIN ISO 8855 [61]. Bedeutende Winkelgeschwindigkeiten sind bzgl. der jeweiligen Bezugskoordinatensysteme eingezeichnet. Der Nachlaufwinkel ϵ ist markiert.	24
Abbildung 3.2: Schnittpunkt von Summenkraftvektor und Reifenaufstandslinie (-punkt in Y - Z -Ebene) ermöglicht die stationäre Kurvenfahrt.	25
Abbildung 3.3: Fahrdynamiksignale bei Einfahrt in eine Rechtskurve, gefiltert mit einem 5 Hz Tiefpassfilter. Das Countersteering des Vorderrads ist im Lenkwinkelsignal blau hinterlegt.	29
Abbildung 3.4: Aufbau eines künstlichen Neurons mit Gewichten (w_i , b) und Aktivierungsfunktion (a) sowie grundlegender Aufbau eines neuronalen Netzes mit Eingabe-, Ausgabe- und verborgenen Schichten (eigene Darstellung).	32
Abbildung 3.5: Informationsfluss und Rechenoperationen in einer LSTM-Zelle (eigene Darstellung). Rechteckige Boxen stehen für Gates mit Sigmoid- (sig) oder Tangens Hyperbolicus (tanh) Aktivierungsfunktion.	33
Abbildung 4.1: Skizze der spiegelsymmetrischen Lenkstange samt Dehnmessstreifen, links in Fahrtrichtung gesehen und rechts in der Draufsicht.	42
Abbildung 4.2: Signalverlauf von ungefiltertem und 5 Hz Tiefpass gefiltertem Lenkmomentsignal in einer 180° -Rechtskurve.	44
Abbildung 4.3: Größenordnungen des gefilterten Lenkmoments in diversen Fahrsituationen mit Angabe der Richtung, in die es aufgebracht wird.	45
Abbildung 4.4: a) Bildausschnitt der Kamera zur Fahrerpositionserfassung. Rückenlinie (grün) und Mittellinie des Motorrads (blau) sind hervorgehoben. Ermittelte Oberkörperlage in φ_F und $y_{F,M5}$ angegeben. b) Seitenansicht des Versuchsmotorrads mit hervorgehobenem Kamera-Sichtfeld.	48

Abbildung 4.5: Signalverlauf von Neigungswinkel φ_F und lateralem Versatz $y_{F,M5}$ des Fahreroberkörpers für eine Kurvenkombination. $y_{F,M5}$ ist ungefiltert und $y_{F,M5,fil}$ mit 2 Hz Tiefpass gefiltert dargestellt.	50
Abbildung 4.6: Signalverlauf des Kopfdrehwinkels (Rohsignal ψ_H und 2 Hz Tiefpass gefiltert $\psi_{H,fil}$) für eine Kurvenkombination.....	52
Abbildung 5.1: Rollrate (a) und Lenkmoment (b) in Kreisfahrt auf 25 m Radius. Mit 5 Hz Tiefpass (fil) und quasistationärem Kriterium (QS) gefilterte sowie über vollständige Kreise (FC) gemittelte Daten. Lenkmomente aus der Mehrkörpersimulation (Sim) zeigen die Abweichung der Simulation.....	54
Abbildung 5.2: Effekt unterschiedlicher Fahrstile der Oberkörperposition auf Lenkmomentbedarf und Fahrzustand in quasistationärer Kreisfahrt auf der 25 m Kreisbahn.	56
Abbildung 5.3: Zeitverlauf der Fahrzustände und Fahrereingaben im 7 m Slalom mit konstanter Geschwindigkeit 40 km/h. Mittlere Amplituden der Signale ausgewertet.	58
Abbildung 5.4: Amplitude der Oberkörperneigung der Fahrer 2 und 3 in allen Slalomfahrten.	59
Abbildung 5.5: Zeitverzug zwischen negierter Fahreroberkörperneigung und Rollwinkel in allen Slalomfahrten mit mindestens 5° Amplitude der Oberkörperneigung. Positive Werte stehen für das Vorseilen der Fahrerbewegung.	60
Abbildung 5.6: Verstärkung von Lenkmomenteingang zu Rollratenzustand in Abhängigkeit der Längsgeschwindigkeit für alle Slalomfahrten.....	61
Abbildung 5.7: Mit der Rollratenamplitude normierter Phasenverzug von Lenkmomenteingang zu Rollratenzustand für alle Slalomfahrten. Positive Werte stehen für das Vorseilen des Lenkmoments.....	62
Abbildung 5.8: Skizze der drei Geometrien für einfache und doppelte Spurwechselmanöver.	63
Abbildung 5.9: Betrag der ersten Amplituden von Fahreroberkörperneigung und Rollwinkel bei einfachen und doppelten Spurwechseln (SW).	64
Abbildung 5.10: Zeitverzug zwischen den ersten Amplituden von Fahreroberkörperneigung und Rollwinkel bei einfachen und doppelten Spurwechseln (SW). Positive Werte stehen für das Vorseilen der Fahrerbewegung.....	64
Abbildung 5.11: Phasenverzug zwischen Lenkmomenteingabe und Fahreroberkörperneigung: a) Grenzfälle des 90° Vorseilen, Synchronität und 90° Nacheilen schematisch dargestellt, b) Werte für alle Slalomfahrten.	66
Abbildung 6.1: Charakterisierung der 21 Testfahrer der Datenerhebung: a) Verteilungen des Alters und der Fahrerfahrung, b) Selbsteinschätzung des Fahrverhaltens.	71

Abbildung 6.2: a) Definition querdynamischer Manöversegmente anhand der Fahrzustände Rollwinkel und -rate (S: Geradeausfahrt, C: quasistationäre Kurvenfahrt, RI: Schräglagenaufbau, RO: Schräglagenabbau, RV: Schräglagenwechsel, Indizes L/R für Richtung). b) beispielhafte Trajektorien der Rollwinkelzustände in 180°-Linkskurve und einfachem Spurwechsel nach links. 73

Abbildung 6.3: Klassifikation von Manöversegmenten für die Fahrmanöver 180°-Linkskurve und einfacher Spurwechsel nach links, erzeugt mittels optimiertem Zustandsautomaten. 74

Abbildung 6.4: Trajektorie der Rolldynamik einer fünfminütigen Fahrt: a) gesamte Messung mit 2 Hz Tiefpass gefiltert, b) Abschnitte mit weniger als 1 s Zeitabstand zwischen Vorzeichenwechseln in der Rollrate mit markierter Rollratengrenze von $|10 \text{ }^\circ/\text{s}|$ 76

Abbildung 6.5: Zeitliche Anteile der querdynamischen Manöversegmente für Fahrt mit mehr als 30 km/h Geschwindigkeit. (S: Geradeausfahrt, C: quasistationäre Kurvenfahrt, RI: Schräglagenaufbau, RO: Schräglagenabbau, RV: Schräglagenwechsel, Indizes L/R für Kurvenrichtung) 77

Abbildung 6.6: Histogramme über die Zeitdauern von Manöversegmenten: a) quasistationäre Kurvenfahrt, b) transiente Segmente. 78

Abbildung 6.7: Formfaktor und Fläche des g-g-Diagramms für jede Messfahrt in a). Vergleich der g-g-Diagramme der Fahrer b) und c) mit stark unterschiedlichem Formfaktor. 80

Abbildung 6.8: Maximale Rolldynamik ausgewertet für jede Messfahrt: a) Mittelwert aus Rechts- und Linkskurve, b) Unterschiede der Extremwerte zwischen Rechts- und Linkskurve. 81

Abbildung 6.9: Fahrerbewegung ausgewertet für jede Messfahrt: a) Spitzenwerte, b) Menge und Kopplung von Oberkörperneigung und lateral Versatz, c) exemplarisches Fahrerbewegungsdiagramm, d) Kopplung der Fahrerbewegung mit dem Rollwinkel. 82

Abbildung 6.10: Verlauf von Kopfdrehwinkel und horizontierter Gierrate für eine beispielhafte Wechselkurve (gefiltert mit 2 Hz Tiefpass). Mittlerer Zeitverzug t und maximaler Korrelationsfaktor ρ (aus Kreuzkorrelation) sowie Median des Signalverhältnisses A sind angegeben. 84

Abbildung 6.11: Statistik zur Korrelation von Kopfdrehwinkel und horizontierter Gierrate für alle einfachen Kurven und Wechselkurven einer Messfahrt. Verteilung von: a) Korrelationsfaktor ρ , b) Median der relativen Amplitude A und c) mittlerem Zeitverzug t 85

Abbildung 6.12: Vergleich von mittlerem Zeitverzug t und relativer Amplitude der Kopfdrehung A über alle Messfahrten in Kurven mit signifikanter Gierraten-Korrelation. Ein Datenpunkt fasst alle einfachen Kurven bzw. Wechselkurven einer Messfahrt zusammen. ... 86

Abbildung 7.1: Beispielhafter Modelltest anhand von: a) Rollwinkel-RMSE aller Testsamples über dem Prädiktionshorizont, b) Rollwinkelprädiktionen an einem einzelnen Testsample...	92
Abbildung 7.2: Umrechnung der Rollwinkel in relative Positionen. a) Herleitung des physikalisch wirksamen Rollwinkels φ_c . b) Fortschreiben der Position zwischen diskreten Prädiktionspunkten.....	93
Abbildung 7.3: Metriken ausgewertet für ein Testsample: a) Rollwinkelprädiktion und RMSE-Fehler, b) errechnete relative Positionen, RMSE des lateralen Positionsfehlers d_{Lat} und Evaluationsindex (EI).....	95
Abbildung 7.4: Parametrische Architektur und Dimensionalität des Datenflusses im Rollwinkelprädiktionsmodell.....	97
Abbildung 7.5: Schritte der Modellentwicklung (links) mit den wichtigsten Ergebnissen (rechts).....	100
Abbildung 7.6: Effekt der Filterung von Eingangssignalen anhand des Verhaltens des Rollwinkel-RMSE über dem Prädiktionshorizont.	102
Abbildung 7.7: Ergebnisse der manuellen Variation der Eingangs-Diskretisierung im Vergleich zum Verhalten der dualen Diskretisierung.....	103
Abbildung 7.8: Finale Architektur und Dimensionalität des Datenflusses im Rollwinkelprädiktionsmodell.....	105
Abbildung 7.9: Prädiktionsgüte der einfachen Annahmen der Geradeausfahrt (rot) und der konstanten Kurvenfahrt (grau) in verschiedenen Metriken, ausgewertet auf dem Testdatensatz.	106
Abbildung 8.1: Vergleich von Vollmodell und Standardbewegungsmodell konstanter Kurvenfahrt in: a) Rollwinkel-RMSE und b) RMSE des lateralen Positionsfehlers über dem Prädiktionshorizont.	108
Abbildung 8.2: Evaluationsindex (EI) von Vollmodell und Standardbewegungsmodell konstanter Kurvenfahrt: a) Verteilung über Testdaten, b) Verbesserung des Vollmodells in Situationen mit $EI < 2$ s.....	109
Abbildung 8.3: Prädiktionsgüte des Rollwinkels aufgeschlüsselt nach Manöversegmenten (MS).	110
Abbildung 8.4: Evaluationsindex (EI) ausgewertet in vier Geschwindigkeitsbereichen: a) Histogramme des EI für das Vollmodell, b) Vergleich der Metriken von Vollmodell (jeweils links, fett) und Standardbewegungsmodell konstanter Kurvenfahrt (jeweils rechts) mit relativer Verbesserung (blau).	112

Abbildung 8.5: Fahrer- & fahrtspezifischer Gesamt-RMSE des Rollwinkels, gemittelt aus 20 Läufen der Kreuzvalidierungen: a) in allen Manöversegmenten (MS), b) bis e) in bestimmten MS. 114

Abbildung 8.6: Prädiktionsgüte ohne Signale der Lenkung, des Fahrerhaltens und der Kombination aus beiden Varianten (Standardmodell). a) Verlauf des Rollwinkel-RMSE. Differenzverläufe von b) Rollwinkel-RMSE und c) lateralem Positions-RMSE bzgl. des Vollmodells. d) Relative Verschlechterung der Metriken im Vergleich zum Vollmodell. ... 118

Abbildung 8.7: Ablationsmatrix zum Effekt einer zusätzlichen Lenkgröße als Eingangssignal. 120

Abbildung 8.8: Ablationsmatrix zum Effekt von zwei Eingangsgrößen der Lenkung. 121

Abbildung 8.9: Beste Ablationsmodelle mit einer & zwei Eingangsgrößen der Lenkung verglichen mit Standardmodell und allen drei Lenkgrößen im Eingang. 122

Abbildung 8.10: Effekt einer zusätzlichen Eingangsgröße des Fahrerhaltens. 124

Abbildung 8.11: Ablationsmatrix zum Effekt zweier zusätzlicher Messgrößen des Fahrerhaltens. 125

Abbildung 8.12: Rollwinkelprädiktion mit allen drei Fahrerhaltensgrößen im Vergleich zum Standardmodell und den besten Ablationsmodellen mit einer & zwei Eingangsgrößen des Fahrerhaltens. 126

Abbildung A.1: Aufbau des Zustandsautomaten zur querdynamischen Manöversegmentierung. ix

Abbildung A.2: Verteilung der Anteile falsch erkannter Schräglagenwechsel und Einrollbewegungen aus Geradeausfahrt über die einzelnen Messfahrten der Datenerhebung. xiii

Abbildung A.3: Rollwinkelprädiktion von Vollmodell und Standardbewegungsmodell konstanter Kurvenfahrt sowie die daraus errechnete Positionsprädiktion für mehrere Zeitpunkte einer beispielhaften Fahrsituation: 30° Rechtskurve und daran anschließende enge 180° Linkskurve mit minimaler Kurvengeschwindigkeit von 43 km/h. xvi

Abbildung A.4: Zeitliche Anteile querdynamischer MS in den Testdaten ausgewertet für unterschiedliche Geschwindigkeitsbereiche (Geschwindigkeit zum Zeitpunkt der Prädiktion). xvii

Tabellenverzeichnis

Tabelle 4.1: Wichtige Eckdaten des Versuchsmotorrads KTM 1290 Super Adventure, Baujahr 2018.....	40
Tabelle 7.1: Hyperparameter der NN-Architektur und deren Einstellung, Wertebereich oder Zwangsbedingung.	96
Tabelle 7.2: Hyperparameter (HP) des NN-Trainings und deren Wert oder Wertebereich.....	96
Tabelle 7.3: Auswahl der Eingangsgrößen für die Rollwinkelprädiktion mit Begründung. Signale von vergleichsweise höherer Dynamik sind mit einem „*“ gekennzeichnet.....	99
Tabelle 7.4: Top 4 Einstellungen der Parametervariation der Eingangszeitreihen-Längen mit Bewertung entsprechend Rollwinkelfehler und Evaluationsindex.	104
Tabelle 8.1: Metriken der lateralen Trajektorienprädiktion von Vollmodell (jeweils links, fett) und SB konstanter Kurvenfahrt (jeweils rechts) nach Manöversegmenten zum aktuellen Zeitpunkt MSt0.	111
Tabelle 8.2: Metriken der Experimente zur längsdynamischen Trajektorienprädiktion.....	128
Tabelle A.1: Parameter und Werte des DMS-Messsystems am Lenker des Versuchsmotorrads.	ii
Tabelle A.2: Übergangsbedingungen des Zustandsautomaten zur querdynamischen Manöversegmentierung.	x
Tabelle A.3: Korrekturen logischer Fehler in der Manöversegmentierung: Typen, Kriterien und Korrekturen.	xi

Liste der verwendeten Abkürzungen und Symbole

Abkürzung	Beschreibung
ABS	Antiblockiersystem
ACC	Adaptive Cruise Control (Abstandstempomat)
ARAS	Advanced Rider Assistance Systems (Sammelbegriff für Motorrad-Fahrerassistenzsysteme)
C	MS: quasistationäre Kurvenfahrt
C-ITS	Cooperative Intelligent Transport Systems (Kooperative Intelligente Verkehrssysteme)
CMC	Connected Motorcycle Consortium (Organisation zur Förderung und Entwicklung von C-ITS Funktionen für Motorräder)
DMS	Dehnmessstreifen
EI	Evaluationsindex
FDE	Final Displacement Error (Abweichung am letzten Prädiktionspunkt)
GNSS	Global Navigation Satellite System (globales Satellitensystem zur Positionsbestimmung)
GT	Ground Truth (erwartetes Ergebnis)
HP	Hyperparameter (Variablen der Architektur und des Trainings neuronaler Netze)
IMU	Inertial Measurement Unit (inertiale Messeinheit)
KS	Koordinatensystem
LSTM	Long Short-Term Memory (Zelltyp eines RNN)
MAE	Mean Absolute Error (mittlerer absoluter Fehler)
MAIDS	Motorcycle Accidents In-Depth Study (Motorrad-Unfallstudie)
MLP	Multi-Layer Perceptron (mehrlagiges Perzeptron)
MS	Querdynamisches Manöversegment

MSC	Motorcycle Stability Control (Motorrad Stabilitätskontrolle)
MSE	Mean Squared Error (mittleres Fehlerquadrat)
NN	Neural Network (neuronales Netz)
PKW	Personenkraftwagen
RI	MS: Schräglagenaufbau
RMSE	Root Mean Squared Error (Wurzel des mittleren Fehlerquadrats)
RNN	Recurrent Neural Network (rekurrente neuronale Netze)
RO	MS: Schräglagenabbau
RTK	Real Time Kinematic (Echtzeitkinematik)
RV	MS: Schräglagenwechsel
S	MS: Geradeausfahrt
SB	Standardbewegungsmodell (in dieser Arbeit verwendetes Referenzmodell der Trajektorienprädiktion)
SM	Standardmodell (RNN-basiertes Prädiktionsmodell, welches ausschließlich Eingangsgrößen verwendet, die in heutigen Serienmotorrädern verfügbar sind)
Indizes	Beschreibung
$\dot{(\cdot)}$	Ableitung nach der Zeit
$(\cdot)^*$	Erwartetes Ergebnis (GT)
$\widehat{(\cdot)}$	Amplitude
$\overline{(\cdot)}$	Mittelwert
$\widetilde{(\cdot)}$	Median
$ (\cdot) $	Betrag
$\overline{(\cdot)}_{FC}$	Messdaten über eine vollständige Runde auf der Kreisbahn gemittelt
$(\cdot)_{QS}$	Mit quasistationärem Kriterium der Querdynamik gefilterte Messgrößen
$(\cdot)_{fil}$	Gefilterte Messgröße
$(\cdot)_{ho}$	Größe im horizontalen Fahrzeug-KS (XYZ)
$(\cdot)_i$	Zeitpunkt auf dem Prädiktionshorizont
$(\cdot)_k$	Iteration des NN-Trainings

$(\cdot)_{l/r}$	Richtungsangabe: links / rechts	
$\Delta(\cdot)$	Differenzgrößen	
Symbole	Beschreibung	Einheit
A	Amplitudenverhältnis	(diverse)
E	Fehler	
F_H	Handkraft des Fahrers an der Lenkstange	N
F_y	Querkraft	N
F_z	Vertikalkraft	N
L	Kostenfunktion für NN-Training	
M_x	Abstützmoment an der Lenkstange	Nm
M_z	Lenkmoment an der Lenkstange	Nm
R	Regularisierung für NN-Training	
R_t	Mittlerer Reifenquerschnitt	m
T_{In}	Diskretisierung der Eingangssequenz der RNN-Schicht	s
T_p	Diskretisierung Prädiktionpunkte im NN-Modellausgang	s
W, w_i	Gewichts-Parameter eines NN	
X, x	Eingangsgrößen eines NN	
Y, y	Ausgangsgrößen eines NN	
a	Aktivierungsfunktion eines künstlichen Neurons	
a_x, a_y, a_z	Längs-, Quer- & Vertikalbeschleunigung	m/s ²
b	Offset-Parameter eines NN	
c	Zellzustand in LSTM-Zelle	
d, d_{Lon}, d_{Lat}	Euklidischer, longitudinaler und lateraler Positionsfehler der Trajektorienprädiktion	m
e	Zwischenergebnis bei Umrechnung von φ in κ	m
f_t, g_t, i_t, o_t	Ausgaben verschiedener Gates in der LSTM-Zelle	
h	Ausgangszustand in LSTM-Zelle	
h_{CG}	Schwerpunkthöhe Motorrad & Fahrer	m
h_{LSTM}	Anzahl der LSTM-Zellen in RNN-Schicht	
$h_{MLP,j}$	Anzahl Neuronen in j-ter Schicht des MLP	
l_{DMS}	Hebelarm der DMS an der Lenkstange	m

l_H	Hebelarm der Handkraft an der Lenkstange	m
$n(EI < 2 \text{ s})$	Anzahl Prädiktionen mit EI-Metrik kleiner 2 s	
n_B	Batchgröße	
n_E	Anzahl Epochen des NN-Trainings	
n_F	Anzahl Eingangsgrößen in Eingangssequenz der RNN-Schicht	
$n_{In(n/h)}$	Anzahl Datenpunkte je Eingangsgröße in Eingangssequenz der RNN-Schicht (für niedrig-/ hochdynamische Signale)	
n_{LSTM}	Anzahl LSTM-Schichten	
n_{MLP}	Anzahl NN-Schichten im MLP	
n_P	Anzahl Prädiktionpunkte im NN-Modellausgang	
p_B	Bremsdruck	bar
p_{Do}	Dropout-Regularisierung nach 1. Schicht im MLP	
t	Zeit	s
t_0	Aktueller Zeitpunkt (Berechnung der Prädiktion)	s
v_x	Längsgeschwindigkeit	m/s
$y_{F(M5)}$	Lateraler Versatz des Fahreroberkörpers (an Marker 5)	cm
α	Phasenverzug	°
α_L	Lernrate NN-Training	
δ	Lenkwinkel	°
θ	Nickwinkel	°
κ	Pfadkrümmung	m^{-1}
ρ	Maximaler Korrelationsfaktor der Kreuzkorrelation	
φ	Rollwinkel	°
φ_F	Neigungswinkel Fahreroberkörper gegenüber. Motorrad-Hochachse	°
φ_c	Schräglage des Schwerpunkts gegenüber dem Reifenaufstandspunkt	°
ψ	Gierwinkel	°
ψ_H	Kopfdrehwinkel des Fahrers um die Rückenlinie des Fahrers	°

1 Einleitung

1.1 Motivation

Das motorisierte Zweirad¹ ist unstrittig eines der bedeutendsten Transportmittel des Individualverkehrs. Es macht mit einem Anteil von 12 % am weltweiten Fahrzeugbestand die zweithäufigste Fahrzeugform nach dem Personenkraftwagen (PKW) aus, wobei der Fahrzeugbestand seit 2011 um 175 % gewachsen ist [2]. Bis zum Jahr 2030 wird weiterhin ein jährliches Wachstum der Verkaufszahlen motorisierter Zweiräder von 3 bis 4 % erwartet [3, 4].

Auf die insgesamt 52 Millionen weltweit im Jahr 2023 gebauten Motorräder entfallen 38 % Mopeds, 59 % Straßenmotorräder und 3 % Offroadmotorräder [4]. Der zahlenmäßig größte Motorradmarkt ist Asien-Pazifik mit 57 % Marktanteil in 2020, vor Europa und Lateinamerika mit jeweils 14 % und Nordamerika mit 11 % [3]. Interessanterweise befinden sich jeweils vier asiatische und vier europäische Länder unter den Top zehn Nationen mit der höchsten Anzahl von Motorrädern je Einwohner; das Motorrad ist damit sowohl in Ländern mit hohem, mittlerem und niedrigem Einkommensniveau beliebt [5]. Dabei wird das Motorrad in Industrienationen sowohl als primäres Fortbewegungsmittel (Nutzungsprofil „Commuting“, insbesondere in europäischen Großstädten anzutreffen) als auch als Freizeit-/Sportgerät (Nutzungsprofil „Leisure“) genutzt; Fahrzeuge, die vorwiegend dem letzteren Zweck dienen, besitzen typischerweise deutlich mehr Motorleistung, Ausstattung und einen höheren Preis [5]. In Schwellen- und Entwicklungsländern dienen Motorräder überwiegend dem Commuting, motiviert durch niedrige Kosten, geringen Platzverbrauch und schnelle Fortbewegung in dichten Verkehrsräumen [3]. Aus Sicht der Nachhaltigkeit sind der geringe Ressourcenbedarf sowohl in der Herstellung (Material- und Energieaufwand) als auch in der Nutzung (Energieverbrauch) im Vergleich zum PKW positiv hervorzuheben [5].

Die unterschiedlichen Nutzungsprofile gehen dabei mit unterschiedlichen Nutzungsräumen einher, die charakteristische Herausforderungen für die Fahrzeugentwicklung und den Fahrer während der Nutzung aufweisen. Während ein zum Commuting genutztes Motorrad vorwiegend innerstädtisch oder in Ballungsräumen bei hohem Verkehrsaufkommen und vergleichsweise niedrigen Geschwindigkeiten gefahren wird, finden Leisure-Fahrten

¹ „Motorisierte Zweiräder“ entsprechen der Fahrzeugkategorie L nach der Nomenklatur der europäischen Wirtschaftskommission [1]. Diese unterscheidet nochmals in die Subkategorien L1 und L3, womit Mopeds mit einer Höchstgeschwindigkeit von maximal 50 km/h (sowie max. 50 cm³ Hubraum, sofern zutreffend) von Motorrädern abgegrenzt werden. Für die Methodik in dieser Arbeit ist diese Abgrenzung nicht von Bedeutung, weshalb der Begriff Motorrad im Folgenden vereinfachend für alle motorisierten Zweiräder verwendet wird.

hauptsächlich im ländlichen Raum bei geringerem Verkehrsaufkommen und mit höheren Geschwindigkeiten statt. Aufgrund der örtlichen Gebundenheit fokussieren sich die Entwicklungen im Rahmen dieser Dissertation auf den europäischen Markt. Insbesondere bzgl. der datenbasierten Methoden ist zu berücksichtigen, dass präsentierte Ergebnisse nicht direkt auf andere Regionen mit stark abweichenden Nutzungsprofilen und -räumen übertragbar sind, die Methoden an sich aber übernommen werden können.

Motorradfahrer gehören wie Fußgänger und Fahrradfahrer zu den vulnerablen Verkehrsteilnehmern, wie ein Anteil von 21 % an den Verkehrstoten weltweit zeigt [2]. Weil Einspurfahrzeuge konzeptbedingt deutlich leichter sind als PKW und keine dedizierte Knautschzone aufweisen, liegt im Vergleich zu mehrspurigen Fahrzeugen nur sehr geringe passive Sicherheit vor. Hohe Verzögerungen bei Kollisionen und die Möglichkeit der Separation von Fahrer und Fahrzeug im Unfallablauf bedingen hohe Verletzungsschweren und Mortalität für Motorradfahrer, sowohl bei Kollisionen mit anderen Verkehrsteilnehmern als auch bei Alleinunfällen. Erstere machen drei Viertel aller Motorradunfälle in Europa aus [6], wobei der Unfallgegner meist ein PKW ist. Setzt man die Fahrleistungen von PKW und motorisierten Zweirädern in Relation zu den Getöteten im Jahr 2019 in der Europäischen Union, so ergibt sich eine um Faktor 16 erhöhte Gefahr eines tödlichen Unfalls pro zurückgelegter Strecke mit dem Motorrad [7, 8]. Eine so deutlich erhöhte Vulnerabilität der Motorradfahrer ist in allen Regionen der Welt zu beobachten und motiviert die Erforschung und Entwicklung von Motorradsicherheitssystemen [9]; als solche werden alle technischen Maßnahmen an Fahrer und Fahrzeug verstanden, die zur Steigerung der Sicherheit beim Motorradfahren beitragen. Andere Maßnahmen zum selben Ziel betreffen die Verbesserung der Straßen-Infrastruktur und des Fahrerverhaltens in Ausbildung und Training, sie werden im weiteren Verlauf der Arbeit nicht behandelt.

Zur Identifizierung von Maßnahmen zur Steigerung der Motorradsicherheit werden Ergebnisse der Unfallforschung herangezogen, z.B. die der MAIDS (engl.: Motorcycle Accidents In Depth Study) [10]. Basierend auf dem Unfallgeschehen werden Bedarfe und mittels weiterer Methoden die Effektivität potenzieller Sicherheitssysteme analysiert und bewertet; für Motorrad-Fahrerassistenzsysteme wird das z.B. in der Dissertation von Köbe durchgeführt [11]. Eine Bedarfsanalyse und Systembewertung anhand von Unfalldaten ist nicht Teil dieser Arbeit. Grundlegende Informationen zum Unfallgeschehen von Motorrädern in Europa sind in Anhang A.1 dargestellt.

Technische Maßnahmen zur Erhöhung der Motorradsicherheit können in passive und aktive Sicherheitssysteme unterschieden werden. Erstere bewirken eine Reduktion der Verletzungsschwere bei Eintritt eines Unfalls. Aufgrund limitierter Effektivität, hoher Kosten und konstruktivem Aufwand haben sich passive Sicherheitsmaßnahmen am Motorrad bisher nicht etabliert. Ein Airbag ist beispielsweise aktuell für ein einziges Motorrad am Markt verfügbar [12]. Entsprechend gibt es für die passive Sicherheit von Motorrädern weder gesetzliche Vorgaben noch Tests durch einen Verbraucherschutz. Passive Sicherheitsmaßnahmen fokussieren sich stattdessen auf den Fahrer, indem je nach Gesetzgebung verschiedene Ausprägung an Schutzbekleidung verpflichtend ist. Trotz aktuell aufkommender Airbag-Schutzbekleidung [13] ist abzusehen, dass passive Sicherheitsmaßnahmen am Motorradfahrer allein keine ausreichende Reduktion der Zahl von Schwerverletzten und Getöteten im Hinblick auf die „Vision Zero“, das Langzeitziel der Europäischen Union im Jahr 2050 nahezu keine Verkehrstoten mehr zu haben, bewirken können. Aus diesem Grund werden aktive Sicherheitssysteme für Motorräder entwickelt und erforscht, welche das Auftreten von Unfällen verhindern sollen.

1.2 Aktive Motorradsicherheitssysteme

Aktive Motorradsicherheitssysteme lassen sich bzgl. ihrer Funktionsphilosophie in die drei Gruppen „Fahrzeugstabilisierung“, „prädiktive Komfort- & Sicherheitssysteme“ und „vernetzte Assistenzsysteme“ unterscheiden. In Abbildung 1.1 sind diesen Gruppen beispielhafte Systeme, bekannt aus dem Serieneinsatz oder der Forschung, zugeordnet.



Vernetzte Assistenzsysteme

Kooperative Intelligente Verkehrssysteme (C-ITS): u.a. Kollisions- & Gefahrenstellenwarnung, Kurvengeschwindigkeitswarnung



Prädiktive Komfort- & Sicherheitssysteme

Abstandstempomat (ACC), Frontkollisionswarnung (FCW), Totwinkelwarnung, autonome Gefahrenbremsung (AEB)

Fahrerassistenz



Fahrzeugstabilisierung

Antiblockiersystem (ABS), Motorrad-Stabilitätskontrolle (MSC): u.a. Kurven-ABS & Traktionskontrolle, Rückstoßaktuatorik

Fahrzeugassistenz

Abbildung 1.1: Drei Gruppen aktiver Motorradsicherheitssysteme mit Beispielfunktionen. Bereits in Serie erhältliche Funktionen sind hervorgehoben.

Systeme der Fahrzeugstabilisierung zielen darauf ab, dass immer ein physikalisch stabiler Fahrzustand gewährleistet wird. Im Serieneinsatz befindliche Systeme greifen dazu in die Längsdynamik des Motorrads ein und verhindern zu hohen Längsschlupf an den Rädern

(Blockieren und Durchdrehen) sowie einen Überschlag aufgrund zu hoher Längsbeschleunigung; dabei wird auch der querdynamische Fahrzustand berücksichtigt [9, 14]. Forschung im Bereich der Fahrzeugstabilisierung untersucht z.B. Lenkungseingriffe zur Stabilisierung von Eigenmoden des Motorrads [15] und neuartige Rückstoßaktuatorik zur kurzzeitigen Erhöhung der abstützenden Seitenkraft in Rutschsituationen [16]. Diese Systeme können auch als Fahrzeugassistenzsysteme bezeichnet werden, weil sie die Kontrollierbarkeit des Fahrzeugs für den Fahrer sicherstellen; entsprechend des Drei-Ebenen-Modells der Fahraufgabe von Donges wirken sie auf der Stabilisierungsebene [14].

Prädiktive Komfort- & Sicherheitssysteme beinhalten Komponenten, welche die Fahrsituation erfassen und den Fahrer bzgl. kritischer Situationen warnen, eingreifen oder bestimmte Fahrzeugzustände kontinuierlich regeln. Mit dem Abstandstempomat (ACC) ist Letzteres auch auf dem Motorrad bereits in Serie. ACC regelt die Geschwindigkeit und stellt einen sicheren Abstand zu vorausfahrenden Fahrzeugen ein. Hierdurch wird dem Fahrer ein Teil der Fahraufgabe abgenommen, was sowohl Komfort- als auch Sicherheitsgewinn darstellt. Als warnende Assistenzsysteme sind heute bereits die Frontkollisions- und Totwinkelwarnung im Serieneinsatz. Aktiv eingreifende Systeme der automatischen Notbremsung (z.B. [17]) und Lenkassistenz (z.B. [18]) befinden sich noch in der Forschung. Alle prädiktiven Komfort- & Sicherheitssysteme müssen die Fahrsituation in der nahen Zukunft antizipieren, weshalb sie prädiktive Sensorik und Algorithmik einsetzen. So wird die Umgebung des Fahrzeugs üblicherweise mittels Kamera-, Lidar- oder Radarsensorik erfasst, um mittels Algorithmik die aktuelle und zukünftige Fahrsituation zu interpretieren.

Vernetzte Assistenzsysteme nutzen die Möglichkeit des Datenaustauschs mit anderen Fahrzeugen, der Straßeninfrastruktur oder einer digitalen Karte zur Verbesserung ihrer prädiktiven Eigenschaft [14]. Beispielsweise stehen dann Informationen zu den zukünftigen Fahrtrajektorien umliegender Fahrzeuge, Gefahrenstellen und dem Straßenverlauf zur Verfügung. Basierend auf letzterer Information werden z.B. Kurvengeschwindigkeitswarner für Motorräder erforscht [19, 20]. Während im PKW bereits erste vernetzte Assistenzsysteme in Serie sind, werden diese für das Motorrad vor allem durch das Connected Motorcycle Consortium (CMC) erforscht [21]. Das CMC strebt an, dass Motorräder am C-ITS (engl.: Cooperative Intelligent Transport Systems) genannten vernetzten Verkehrssystem teilnehmen, indem sie ihre zukünftigen Fahrtrajektorien mit anderen Verkehrsteilnehmern austauschen [22]. Dadurch sollen Kollisionen mit Motorrädern stärker verhindert werden.

Sowohl prädiktive als auch vernetzte Systeme können unter dem Begriff der Fahrerassistenzsysteme zusammengefasst werden; für Motorräder wird meist die Abkürzung ARAS verwendet

(für engl.: Advanced Rider Assistance Systems). ARAS unterstützen den Fahrer entsprechend des Drei-Ebenen-Modells nach Donges auf der Bahnführungsebene [14].

Aus der Historie aktiver Sicherheitssysteme wird ersichtlich, dass diese „von oben“ in den Markt eingeführt werden, d.h. zuerst in hochpreisigen und leistungsfähigen Motorrädern zum Einsatz kommen. So wurde das Antiblockiersystem (ABS) im Jahr 1988 von BMW in sportliche Tourenmotorräder eingebaut [14]. Inzwischen hat es den Markt „nach unten“ durchdrungen, denn seit dem Jahr 2017 ist das Motorrad-ABS im Großteil der Europäischen Union für Fahrzeuge mit mehr als 125 cm³ Hubraum gesetzliche Pflichtausstattung [23]. Auch heute erfolgt die Entwicklung von ARAS zunächst für Motorräder der Oberklasse und orientiert sich deshalb an deren Nutzungsprofil und -raum.

1.3 Problemstellung

Wie in Abschnitt 1.2 erläutert ist, benötigen ARAS Information über die zukünftige Fahrsituation, zumeist ausgedrückt in Form vorausliegender Positionen eines Fahrzeugs. Wenn diese über der Zeit definiert sind, spricht man von der Positions- oder auch Fahrtrajektorie. Für bestimmte Assistenzfunktionen müssen die Positionstrajektorien umliegender Fahrzeuge bekannt sein, in jedem Fall wird aber die vorausliegende Fahrtrajektorie des Ego-Fahrzeugs, also des Motorrads, benötigt. Die im Stand der Technik für die Trajektorienprädiktion eingesetzten einfachen physikalischen Bewegungsmodelle sind insbesondere in Kurvenfahrt in ihrer Prädiktionsgüte begrenzt, d.h. die Trajektorie kann nur über einen kurzen Zeitraum vorhergesagt werden.

Neue ARAS können aber erst in den Markt eingeführt werden, wenn eine ausreichende Funktionstüchtigkeit sichergestellt ist. Für warnende Assistenzfunktionen besteht das sogenannte Warndilemma: im Sinne der Wirksamkeit einer Warnung ist diese möglichst früh an den Fahrer auszugeben, damit diesem ausreichend Reaktionszeit bleibt, was jedoch das Risiko von Falschwarnungen erhöht [14]. Bei einer eingreifenden Funktion besteht das Risiko der Fehlauflösung und dadurch bedingter Gefährdung des Fahrers und anderer Verkehrsteilnehmer. Für beide Funktionstypen kann das Risiko eines falsch reagierenden Assistenzsystems durch eine hohe Güte der Trajektorienprädiktion verringert werden. Es ist deshalb entscheidend für die Ermöglichung neuer ARAS, dass bessere Algorithmen der Prädiktion entwickelt werden, die besonders in den relevanten Fahrsituationen der Kurvenfahrt über einen ausreichend langen Prädiktionshorizont verlässliche Information liefern.

Bei den ARAS auf Bahnführungsebene kann der mindestens erforderliche Prädiktionshorizont mit 2 bis 3 s angegeben werden [14]. Für C-ITS Funktionen werden sogar bis zu 6,5 s als Anforderung genannt [22]. Weil der Fahrer die Fahrtrajektorie entlang des Prädiktionshorizonts

durch seine Eingaben in das Motorrad beeinflusst, muss ein Algorithmus der Trajektorienprädiktion eine Annahme oder Information bzgl. der Fahrerabsicht berücksichtigen [14]. Diese kann z.B. aus typischen Mustern der Fahrdynamik oder des Fahrerverhaltens abgeleitet werden. Die im Vergleich zum PKW stark unterschiedliche Querdynamik des Zweirads verhindert eine direkte Übernahme von Methoden und führt gleichzeitig zu zusätzlichen Herausforderungen. Beispielsweise dient ein Teil der querdynamischen Fahrereingaben auf dem Motorrad – anders als im PKW – der Stabilisierung der Kippdynamik und nicht der Bahnführung. Weiterhin bestehen im Hinblick auf die Kurvenfahrt des Motorrads mit den Zustandsgrößen der Lenkung sowie den querdynamischen Fahrereingaben des Lenkmoments und der Schwerpunktverlagerung² Messgrößen, für die noch wenig Erfahrung vorhanden ist, weil sie in bisherigen Serienmotorrädern nicht gemessen werden. In ihnen wird Potential für eine verbesserte Trajektorienprädiktion in Kurvenfahrt gesehen – ähnlich zum Lenkwinkel im PKW, der als eine Art Vorsteuerung für die Trajektorienprädiktion wirkt.

1.4 Zielstellung und Vorgehen

Die im vorherigen Abschnitt vorgestellten Anforderungen bestehender und zukünftiger ARAS sowie die Herausforderungen des Zweirads motivieren die Forschung an motorradspezifischen Algorithmen zur Trajektorienprädiktion des Ego-Fahrzeugs. Ziel der Dissertation ist die Entwicklung eines solchen Algorithmus unter Einsatz der neuartigen Messgrößen des Fahrzustands in der Lenkung und querdynamischer Fahrereingaben, die in bisherigen aktiven Sicherheitssystemen des Motorrads nicht verwendet werden.

Zunächst ist zu überprüfen, ob ein Einsatz der neuen Messgrößen querdynamischer Fahrereingaben in physikalischen Algorithmen der Trajektorienprädiktion erstrebenswert ist. Alternativ wird eine manöverbasierte Trajektorienprädiktion angestrebt (die Klassifikation der Ansätze zur Trajektorienprädiktion ist in Abschnitt 2.2 erläutert). Dieser Typ könnte auch weitere Informationsquellen wie Karten oder Umfeldsensorik für die Prädiktion nutzen, worauf in dieser Arbeit aber bewusst verzichtet wird; aus Gründen der Verfügbarkeit solcher Sensorik, der angedachten Funktion (detaillierte Erläuterung in Abschnitt 7.1) und des Fokus auf die neuartigen Messgrößen wird die intrinsische Systemsicht gewählt, d.h. es werden ausschließlich Größen der Fahrdynamik und des Fahrers für die Trajektorienprädiktion verwendet.

² Die querdynamisch wirksame Fahrereingabe der Schwerpunktverlagerung ergibt sich aus der besonderen Querdynamik des Einspurfahrzeugs. Sie wird in den Abschnitten 2.1 und 3.1 genauer erläutert.

Um den Fokus der Untersuchungen auf die querdynamischen Eigenheiten des Einspurfahrzeugs und seiner Steuerung in Kurvenfahrt durch den Fahrer zu legen, wird eine rein laterale Trajektorienprädiktion angestrebt. Bzgl. dieser stellen sich folgende Forschungsfragen:

- RQ1: Wie verhält sich ein motorradspezifischer Algorithmus zur lateralen Trajektorienprädiktion, der neuartige Informationen über die Zustandsgrößen der Lenkung und querdynamische Fahrereingaben verwendet, gegenüber einem Standardbewegungsmodell?
- RQ2: Welche Vorausschauzeiten sind mit dem entwickelten Algorithmus in diversen Fahrsituationen erreichbar?
- RQ3: Welche Bedeutung haben die neuartigen Messgrößen des Fahrzustands in der Lenkung und querdynamischer Fahrereingaben für die Trajektorienprädiktion?

Nach der Einführung des Stands der Technik zu querdynamischen Fahrereingaben und Fahrerverhalten beim Motorradfahren und zur Trajektorienprädiktion in Kapitel 2, werden die Grundlagen der Zweiraddynamik und Verarbeitung von Zeitreihendaten in neuronalen Netzen in Kapitel 3 erläutert. Dabei wird motiviert, dass ein Versuchsmotorrad zur Erfassung von Fahrereingaben und -verhalten im Fahrversuch aufgebaut werden muss. Das Fahrzeug und im speziellen die eingesetzte Sondermesstechnik zur Erfassung der Fahrzustände der Lenkung, querdynamischer Fahrereingaben und des Fahrerverhaltens werden in Kapitel 4 vorgestellt.

Mittels gezielter Fahrmanöver wird in Kapitel 5 das querdynamische Übertragungsverhalten des Versuchsmotorrads unter verschiedenen Fahrereingaben identifiziert. Auf Basis der Ergebnisse und mit dem Wissen über die Modellierung der Zweiraddynamik aus Abschnitt 3.1 wird das Potenzial einer motorradspezifischen physikalischen Trajektorienprädiktion bewertet. Außerdem wird das beobachtete Fahrerverhalten bzgl. unterschiedlicher Motivationen des Fahrers interpretiert.

Nachdem sich für die Realisierung einer manöverbasierten Algorithmik der lateralen Trajektorienprädiktion auf Basis der Methode des maschinellen Lernens entschieden wird, beschreibt Kapitel 6 die Erhebung eines großen Fahrdatensatzes, der für dessen Entwicklung benötigt wird. Dabei wird zudem die Algorithmik der Manöversegmentierung eingeführt, die für die systematische Analyse der Fahrdaten eingesetzt wird.

Kapitel 7 erläutert die Entwicklung eines RNN-basierten Rollwinkelprädiktionsmodells, mit dem die laterale Trajektorienprädiktion realisiert wird. Die Prädiktionsgüte des motorradspezifischen Modells und die Bedeutung der neuartigen Messgrößen werden in Kapitel 8 mit diversen Auswertungen und Ablationsstudien ausführlich untersucht. Basierend auf den

1.4 Zielstellung und Vorgehen

Ergebnissen werden zum Schluss Antworten auf die Forschungsfragen gegeben und die gewählten Methoden diskutiert.

2 Stand der Forschung

Zu den Fahrereingaben des Motorradfahrers in Kurvenfahrt, die in Serienmotorrädern aktuell nicht erfasst werden, gibt es diverse Untersuchungen im Stand der Forschung, in denen Motorradfahrer vermessen und ihr Verhalten analysiert wird. Sie alle beschäftigen sich mit der besonderen Fahrphysik von Zweirädern in Kurvenfahrt, motivieren sich aber durch verschiedene Fragestellungen aus den Bereichen Motorrad-Design, virtueller Fahrerregler, Fahrertraining und Fahrstilanalyse. Um Verständnis für die Fahrereingaben und das Fahrerverhalten in Querdynamik zu erlangen, gibt Abschnitt 2.1 Einblick in diesen Stand der Forschung.

Abschnitt 2.2 führt anschließend in den Themenkomplex der Trajektorienprädiktion ein. Weil hier nur wenige Aktivitäten im Motorradbereich vorhanden sind, werden auch Entwicklungen des hochautomatisierten Fahrens im PKW betrachtet.

2.1 Fahrereingaben und -verhalten in Querdynamik

Motorradfahren, speziell die Kurvenfahrt mit dem Motorrad, ist kompliziert, denn zum einen sind Einspurfahrzeuge nicht in allen Fahrzuständen eigenstabil, d.h. es ist in bestimmten Situationen ständige aktive Stabilisierung durch Eingaben des Fahrers notwendig. Aufgrund der Kippdynamik führen Fahrfehler oder externe Störungen außerdem schnell zum Sturz. Zum anderen gibt es aufgrund multipler querdynamischer Eingangsgrößen theoretisch unendlich viele Kombinationen an Fahrereingaben, um eine einzige Kurventrajektorie zu absolvieren. Dies liegt an der im Vergleich zum PKW ungleich komplexeren Fahrphysik, dessen Grundlagen in Abschnitt 3.1 erläutert werden.

Das Fahrerlenkmoment ist die primäre Eingangsgröße der Motorradquerdynamik. Aufgrund der Schräglage in Kurven kommt hinzu, dass eine laterale Verschiebung des Systemschwerpunkts durch Verlagerung des Fahrergewichts ebenfalls als Eingangsgröße wirkt – diese wird auch als Fahrerrollmoment bezeichnet. Unter anderem dieses Wechselspiel mehrerer Eingangsgrößen macht den Reiz des Motorradfahrens aus, wird von Fahrer zu Fahrer unterschiedlich genutzt und durch den Term Fahrstil beschrieben. Der Begriff Fahrerverhalten beinhaltet den Fahrstil, reicht aber weiter und betrachtet auch die zeitliche Abfolge von Aktionen und daraus resultierenden Fahrzuständen.

Nicht allein aufgrund der Komplexität der Querdynamik erfordert Motorradfahren Übung und lebt von Erfahrung. Der große Reiz des Kurvenfahrens birgt dabei Herausforderungen für die

2.1 Fahrereingaben und -verhalten in Querdynamik

Entwicklung von Fahrerassistenzsystemen, weil diese für eine große Bandbreite unterschiedlicher Fahrerfähigkeiten und -stile funktionieren müssen.

Untersuchungen zu den Fahrereingaben in querdynamischen Fahrmanövern haben in den 1970er Jahren an Bedeutung gewonnen. Zielstellung damals war es, die Stabilität und das Handling von Motorrädern systematisch zu untersuchen und mittels Kennzahlen zu objektivieren, um das Design neuer Fahrzeuge zu verbessern. Unter dem Begriff Handling werden sowohl das Stabilitätsverhalten als auch die Reaktionen eines Fahrzeugs auf Fahrereingaben verstanden [24].

Eine ausführliche Übersicht zu den diversen Untersuchungen des Zweirad-Handlings wird im Review von Kooijman und Schwab [24] gegeben. Sowohl experimentell [25, 26] als auch simulativ [27, 28] wurde in diversen Untersuchungen das Übertragungsverhalten der Fahrereingaben Lenk- und Rollmoment auf die Fahrzeugreaktion untersucht. Sie kommen zum übereinstimmenden Ergebnis der sehr niedrigen Effektivität des Fahrerrollmoments im Vergleich zum Lenkmoment; zwischen den Verstärkungen beider Eingangsgrößen besteht rund eine Zehnerpotenz Unterschied [29]. Dabei werden jedoch keine Kreuzeffekte, d.h. die gegenseitige Beeinflussung der querdynamischen Fahrereingaben, berücksichtigt. Evertse [30] bestätigt in einer Fahrstudie mit unterschiedlichen Fahrern, dass das Fahrerrollmoment eine sehr ineffektive Eingabe ist und stellt dennoch fest, dass unterschiedliche Fahrstile in der Oberkörperbewegung das Lenkmomentübertragungsverhalten stark beeinflussen. Damit wirkt sich die Fahrerbewegung indirekt doch auf das Handling aus.

Im Hinblick auf Lenk-Assistenzsysteme sind Untersuchungen des Handlings noch heute aktuell. Bartolozzi, Savino & Pierini [31] entwickeln eine Lenkmomentschätzung für stationäre und transiente Fahrmanöver, die auf Fahrzuständen und nur wenigen Parametern des Motorrads basiert. Im Vergleich mit Lenkmomentmessungen wird ermutigende Übereinstimmung der Schätzung festgestellt. Anhand ihrer empirischen Gleichungen untersuchen die Autoren das Übertragungsverhalten des Lenksystems, führen dafür jedoch keine Validierung durch.

Mit dem Aufkommen der Simulationstechnik ergab sich die zweite große Motivation für Untersuchungen zur Bedeutung und Nutzung von Fahrereingaben, weil es nun galt, vereinfachte Motorradmodelle und Fahrerregler zu entwerfen. Die Fragestellung lautet, unter welchen Bedingungen die Fahrerbewegung zur lateralen Schwerpunktverlagerung für eine erfolgreiche Simulation abgebildet werden muss. Hierbei kann nochmals in Stabilisierung (Verhindern des Umkippens) und Pfadfolgeregelung (Ausführen eines Manövers) unterschieden werden [24].

Ein ausführliches Review zu Fahrermodellen für die Motorradsimulation liefern Popov, Rowell & Meijaard [29]. Sie zeigen, dass es viele Methoden zur erfolgreichen Stabilisierung und Trajektorien-Regelung von Motorrädern gibt, sowohl mit nur einem Lenkmomenteingang als auch mit zusätzlichen Fahrerbewegungseingängen. Trotz der bereits genannten niedrigen Effektivität der lateralen Fahrerbewegung als querdynamische Eingangsgröße zeigen Bruschetta et al. [32] die Notwendigkeit dessen Berücksichtigung, wenn Fahrten nahe des fahrdynamischen Grenzbereichs simuliert werden sollen. Alle simulativen Fahrerregler haben gemein, dass der Realismus des Reglerverhaltens noch ungeklärt ist, weshalb die Validierung natürlichen Fahrerhaltens als zentrale Forschungsfrage für zukünftige Entwicklungen genannt wird [29]. Das Verständnis für reales Fahrerverhalten ist demnach sowohl für die Fahrzeugentwicklung bzgl. Stabilität und Handling als auch für die erfolgreiche Simulation essenziell; im späteren Verlauf des Kapitels wird deshalb auf beschreibende Untersuchungen realen Fahrerverhaltens eingegangen.

Weiterhin ist der Fahrer mit seiner Masse selbst Teil des dynamischen Systems und aufgrund der Massenverhältnisse – als Anhaltswert macht der Fahrer zwischen einem Viertel und Drittel der Gesamtsystemmasse aus – beeinflussen seine Massenträgheit und Bewegungen die Fahrdynamik signifikant. Bzgl. der Simulation stellt sich also nicht nur die Frage nach dem Regelverhalten des Fahrers, sondern auch nach seiner Modellierung als Teil des mechanischen Systems. Es gibt unterschiedliche Möglichkeiten den Kontakt zwischen Fahrer und Fahrzeug zu modellieren. Im einfachsten Fall wird der Fahreroberkörper als starr mit dem Hauptrahmen verbundene Masse dargestellt, was realistisch ist, wenn keine signifikante Relativbewegung vorhanden ist [24]. Alternativ wird dem Oberkörper ein rotatorischer Freiheitsgrad um die Längsachse des Hauptrahmens auf Höhe des Sattels gegeben, an welchem er mit Feder und Dämpfer angebunden ist [24]. Scherer, Pleß und Winner [33] beziehen mit ein, dass der Fahrer in Realität auch mit dem Lenker verbunden ist und untersuchen die Kopplung von Fahrerneigungs- und Lenkeingaben. Solche Kopplungsansätze, ebenfalls von Zhu, Murakami & Nishimura [34], Cossalter et al. [35] und Lane & Lot [36] realisiert, wirken sich wiederum auf den Fahrerregler aus, weil beide Fahrereingaben miteinander verkoppelt sind.

Eine weitere Motivation für die Untersuchung des querdynamischen Fahrerverhaltens kommt aus der Unfallforschung, wo insbesondere die Linienwahl innerhalb der Fahrspur von Interesse ist. Beispielsweise untersuchen Winkelbauer, Krack & Lamp [37] Fahrlinie und -stil in Kurven mit stationären Kameras, um die Auswirkungen von Fahrbahnmarkierung auf Fahrerverhalten zu bestimmen.

Mit der Beobachtung querdynamischer Fahrereingaben, Fahrzustände und Fahrerverhaltens wird weiterhin angestrebt, die Fahrfertigkeit von Motorradfahrern zu bewerten. Dies kann sowohl zu Ausbildungs- und Trainingszwecken als auch zur automatischen Adaption von Assistenzfunktionen an den Fahrer dienen.

In der Dissertation von Magiera [38] wird eine Methode zur Bestimmung der Fahrfertigkeit anhand des Fahrverhaltens in Kurvenfahrt entwickelt. Nach der Zerlegung eines beliebigen Kurvenmanövers in sich wiederholende Abschnitte, sogenannte Manöver-Primitive, werden unterschiedliche Kennwerte der Fahrfertigkeit für die jeweiligen Manöver-Primitive bestimmt. In stationärer Kurvenfahrt werden beispielsweise die Welligkeit der Rollbewegung und Anzahl an Rollwinkelkorrekturen ausgewertet.

Bartolozzi et al. [39] untersuchen das Fahrdynamik- und Fahrereingabeverhalten (Lenkmoment, Fußrastenkräfte und Gewichtsverlagerung) von sieben Fahrern mit unterschiedlicher Fahrerfahrung bei wiederholten Durchfahrten durch drei Kurven einer kurzen Teststrecke. Hierbei zeigt sich, dass große Unterschiede im Fahrereingabeverhalten kein sinnvolles Clustering der Fahrer erlauben. Es werden positive Korrelationen der Fahrerfahrung mit dem Längsruck und der Nutzung überlagerter Längs- und Quereschleunigung aufgezeigt.

In der Auswertung einer umfangreichen Fahrstudie im öffentlichen Straßenverkehr nutzen Will et al. [40] das g-g-Diagramm zur Unterscheidung unterschiedlicher Fahrerverhaltenstypen. Dazu wird die Form der vom Fahrer ausgenutzten Längs- und Quereschleunigung einer der drei Klassen „flach“, „kopfstehendes Herz“ und „blattformig“ zugeordnet. Aus den umfangreichen Daten folgern die Autoren, dass Fahrerverhalten eine konstante Eigenschaft ist, und damit nicht von der Tagesform des Fahrers abhängt. Das charakteristische Fahrerverhalten wird dabei schon nach einer Fahrstrecke von etwa 50 km auf der Landstraße sichtbar, d.h. Form und Größe des g-g-Diagramms verändern sich im weiteren Fahrtverlauf nicht mehr signifikant. Allerdings wird angemerkt, dass die Kurvencharakteristik der gefahrenen Strecke einen Einfluss auf das Ergebnis haben kann. Will et al. [40] sehen keine Evidenz, dass Fahrleistung oder Führerscheinalter mit dem Fahrverhalten korrelieren. Stattdessen werden Fragebögen zur Selbsteinschätzung vorgeschlagen, denn z.B. Fragen zum Überholverhalten zeigen eine Korrelation mit dem beobachteten Fahrverhalten.

Wenn eine qualitative Beschreibung des Motorradfahrerverhaltens erfolgt, werden häufig die drei Fahrstile Legen, Drücken und Hängen verwendet. Sie unterscheiden sich in der Positionierung des Fahreroberkörpers in Kurvenfahrt relativ zum Motorrad, was in Form von Skizzen in Abbildung 2.1 dargestellt ist. Beim Legen bewegt sich der Fahrer nicht relativ zum Fahrzeug und sitzt mittig, sodass sein Oberkörper eine Linie mit dem Motorrad bildet; dieser Fahrstil benötigt wenig Kraft [37]. Im drückenden Fahrstil lehnt der Fahrer den Oberkörper

relativ zum Motorrad nach kurvenaußen, der Sitzpunkt bleibt dabei mittig auf dem Sitz oder bewegt sich auch leicht nach kurvenaußen. Drücken wird insbesondere in engen Kurven, Abbiege- und Ausweichmanövern angewendet, weil die absolut gesehen geringere Schräglage des Oberkörpers Situationsübersicht und Kontrollgefühl verbessert [37]. Beim Hängen verschiebt der Fahrer seinen Oberkörperschwerpunkt nach kurveninnen, was in erster Linie durch einen lateralen Versatz des Sitzpunkts erreicht wird. Winkelbauer, Krack & Lamp [37] unterscheiden zwei Ausprägungen des Hängen, je nachdem in welche Richtung der Oberkörper zusätzlich zur Verschiebung des Sitzpunkts geneigt wird. Ist der Oberkörper im normalen „Hängen“ parallel zum Motorrad oder sogar nach kurvenaußen geneigt, wird er beim „Hanging-Off“ zusätzlich nach kurveninnen gelehnt. Mit Letzterem wird somit eine maximale Verschiebung des Fahrerschwerpunkts nach kurveninnen erreicht, die teilweise noch durch ein Ausklappen des kurveninneren Knies und Ellenbogens maximiert wird. Mit diesem körperlich und technisch anspruchsvollen Fahrstil können höchste Querbeschleunigungen erreicht werden, weshalb er vorwiegend auf Rennstrecken anzutreffen ist.

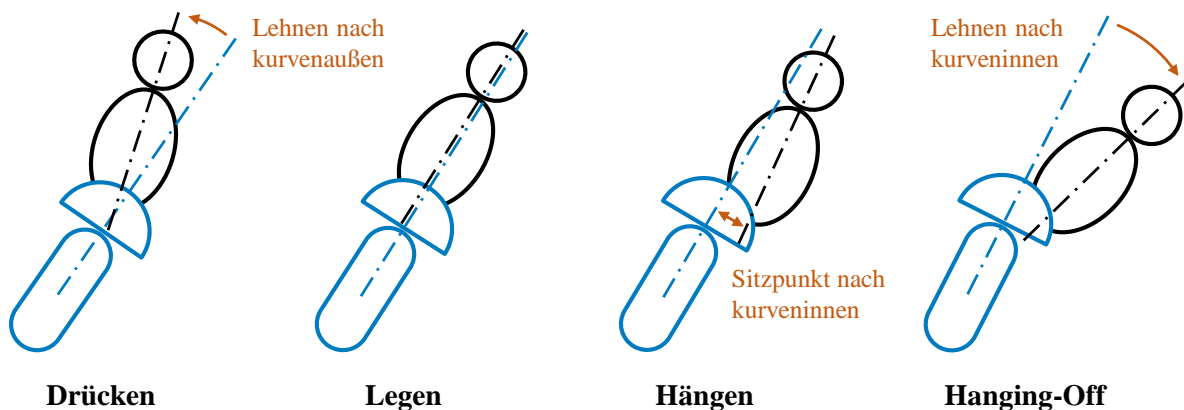


Abbildung 2.1: Schematische Darstellung typischer Fahrstile der Oberkörperbewegung auf dem Motorrad. Die Skizzen zeigen jeweils eine Rückansicht von Fahrer und Fahrzeug.

Die letzte verbleibende Motivation zur Betrachtung von Fahrereingaben und -verhalten ist die Entwicklung von fahrerspezifischen Verhaltensmodellen oder Prädiktionsmodellen. Scherer und Basten [41] untersuchen die Kurvenfahrt von Motorradfahrern in einer Probandenstudie auf individuelle Muster im Fahrerverhalten. Hierbei betrachten sie jedoch nicht die Fahrereingaben, sondern den Rollwinkelzustand des Motorrads und damit die Auswirkung des Fahrerverhaltens im Fahrzustand. Identifizierte Verhaltensmuster können für zielgerichtetes Fahrertraining oder -feedback eingesetzt werden. Die Autoren zeigen außerdem eine fahrerspezifische Trajektorienprädiktion in Kurvenfahrt auf. Im folgenden Abschnitt 2.2 wird nochmals detaillierter auf diesen und weitere Ansätze eingegangen.

Wie in den vorhergehenden Absätzen dargestellt, besteht in den meisten Untersuchungen der Bedarf, zu gemessenen Fahrereingaben auch die Gründe für das dahinterstehende Fahrerverhalten in Kurvenfahrt zu verstehen. Dabei besteht der Konsens, dass die Nutzung von Fahrerbewegung aufgrund ihrer niedrigen Effektivität als querdynamische Fahrereingabe nicht allein mit der Verbesserung des Handlings begründet werden kann. Bei der Erläuterung gebräuchlicher Fahrstile in Abbildung 2.1 sind bereits weitere Gründe genannt, warum Motorradfahrer trotzdem ihren Schwerpunkt verlagern. Aus den Fahrversuchen verschiedener Untersuchungen werden unterschiedliche Beobachtungen des Fahrerverhaltens beschrieben, zu denen die Autoren jeweils Erklärungsansätze liefern.

In transienten Spurwechsel- und Slalommanövern wird einheitlich ein Lehnen des Oberkörpers entgegengesetzt zum Fahrzeugrollwinkel beobachtet [26, 30, 42]; dabei wird jeweils angemerkt, dass es sich nicht um eine aktive Bewegungseingabe des Fahrers, sondern um eine Reaktion auf die Fahrzeugbewegung handelt; dies wird z.B. anhand eines konstanten Phasenverzugs zwischen Oberkörper- und Fahrzeugrollwinkel im Slalom erkannt [42]. Das Verhalten findet aus Komfortgründen statt, denn der aufrecht gehaltene Oberkörper erfährt weniger Rollbeschleunigung in den transienten Manövern. In [26, 42] wird zudem festgestellt, dass Fahrer das Einlenken in den Spurwechsel mit zunehmender Erfahrung stärker durch eine laterale Verschiebung des Sitzpunkts antizipieren. Sobald eine schnelle Ausweichreaktion gefordert ist, verschwindet dieses Verhalten jedoch wieder [30].

Auch in einem realistischen 90°-Kurvenmanöver wird gleichermaßen eine reaktive Oberkörperbewegung nach kurvenaußen, entgegengesetzt zum Fahrzeugrollwinkel beobachtet, die aus Komfortgründen stattfindet [30]. Bocciolone et al. [43] stellen in stationärer Kurvenfahrt zusätzlich eine laterale Verschiebung des Sitzpunktes nach kurveninnen fest, welche den Fahrerschwerpunkt so verschiebt, dass die Kurve mit weniger Rollwinkel durchfahren werden kann.

Evertse [30] beobachtet außerdem eine vergrößerte Amplitude der Oberkörperbewegung bei nasser Fahrbahn im gleichen 90°-Kurvenmanöver und erläutert, dass die höhere mentale Belastung bei erschwerten Bedingungen dazu führt. Mit zunehmend schwieriger Fahraufgabe erkennen Kooijman & Schwab [24] ein Angleichen der querdynamischen Eingaben von Fahrern unterschiedlicher Erfahrungsniveaus. Prem & Good [44] bemerken in Fahrversuchen, dass die Oberkörperbewegungen und Lenkeingaben unerfahrener Motorradfahrer stärker miteinander verkoppelt sind als die erfahrener Fahrer. Sie erklären, dass erstere bewusst die Oberkörperbewegung steuern und dies aufgrund eines versteiften Oberkörpers unbewusst zu Lenkeingaben führt; erst mit zunehmender Fahrerfahrung können die Fahrer die Lenkung unabhängig ansteuern. Ihre Erläuterungen widersprechen damit den Vorherigen, welche die

Oberkörperbewegung als Reaktion aus Komfortgründen und nicht als bewusste Fahrereingabe dargestellt haben.

Aus wenigen Veröffentlichungen sind motorradspezifische physiologische Parameter zu den querdynamischen Fahrereingaben vorhanden. Lane & Lot [36] zeigen in ihren Untersuchungen zur Kopplung von Fahreroberkörperbewegung und Lenkung, dass aktive Fahrereingaben unterhalb der Frequenz von 2 Hz erfolgen. So haben Fahrer typischerweise Schwierigkeiten bei der Kontrolle von Pendelschwingungen, die in einem Bereich von 2 bis 3 Hz auftreten [45]. Für besonders fähige Motorradfahrer wird das obere Ende des kontrollierbaren Frequenzbereichs in der Lenkung erst bei 5 Hz gesehen [46]. Als üblicherweise maximal ausgenutzte Amplitude des Lenkmoments werden 100 Nm angegeben [46], wobei dies stark vom verfügbaren Hebel am Lenker des Motorrads abhängt.

Zusammengefasst kommen die bisherigen Untersuchungen zur physikalischen Bedeutung der zwei querdynamischen Fahrereingaben – in Form von Simulationen und Fahrversuchen – zum übereinstimmenden Ergebnis, dass die laterale Fahrerbewegung im Vergleich zum Lenkmoment eine vielfach weniger effektive Eingabe ist. Teilweise wird aber von einer signifikanten Beeinflussung des Lenkmoments durch Fahrstile berichtet. Jede einzelne Literaturquelle betrachtet dabei nur wenige oder nicht ausreichend definierte Fahrmanöver und es ist keine aktuelle Arbeit bekannt, welche das querdynamische Übertragungsverhalten des Motorrads experimentell sowohl in quasistationären als auch transienten Manövern und unter Einfluss verschiedener Fahrereingaben systematisch untersucht. Deshalb wird im Rahmen dieser Arbeit eine umfangreiche Systemidentifikation anhand von Fahrversuchen durchgeführt und in Kapitel 5 beschrieben. Deren Ergebnisse dienen auch der Bewertung der Nützlichkeit der querdynamischen Fahrereingaben im Sinne einer physikalischen Trajektorienprädiktion.

Die in der Literatur beschriebenen Fahrversuche münden teilweise in verschiedenen Beobachtungen bzgl. dem Einsatz der Fahrerbewegung. Dementsprechend leiten die Autoren unterschiedliche Gründe und Motivationen für die Fahrstile beim Motorradfahren ab. Für die in Kapitel 5 beschriebenen Fahrversuche werden eigene Schlussfolgerungen zum Fahrerverhalten gezogen. Basierend auf einem selbst erhobenen Datensatz mit mehreren Fahrern werden in Abschnitt 6.3 die Unterschiede im Fahrerverhalten im Straßenverkehr analysiert.

2.2 Trajektorienprädiktion

Lefèvre, Vasquez & Laugier [47] unterscheiden Ansätze zur Trajektorienprädiktion in ihrem Review-Artikel entsprechend der dahinterstehenden Hypothese über das Fahrzeugverhalten in drei Klassen:

- 1) *Physikalische Modelle* berechnen die zukünftige Fahrtrajektorie basierend auf dynamischen oder kinematischen Modellen des Fahrzeugs. Sie treffen Annahmen, wie sich Eingangsgrößen bzw. Zustandsgrößen dieser Modelle über den Prädiktionshorizont verhalten. Informationen über die Fahrerabsicht zum aktuellen Zeitpunkt werden dabei nicht berücksichtigt. Dieser Modelltyp ist weitverbreitet und wird in Serie eingesetzt, erreicht jedoch nur auf einem Prädiktionshorizont von rund einer Sekunde gute Resultate. Als einfachste kinematische Modelle werden Punktmassen mit den Annahmen konstanter Geschwindigkeit oder Beschleunigung und Gierrate eingesetzt.
- 2) *Manöverbasierte Modelle* beziehen auch Informationen zur Fahrerabsicht mit ein (auch als verhaltensbasierte Modelle bekannt), indem aus Fahrzuständen, Fahrereingaben oder Umgebungsinformationen – meist implizit, teilweise auch explizit – auf das vom Fahrer angestrebte Fahrmanöver geschlossen wird. Mit dieser a priori Information über die vorausliegende Fahrtrajektorie werden längere Prädiktionshorizonte als in 1) erreicht. Beispielsweise wird in einem deterministischen Ansatz von Houenou et al. [48] der vorausliegende Spurverlauf (Umgebungsinformation) mit der Fahrzeugorientierung verglichen, um einen Spurwechsel zu erkennen und eine Trajektorie zu berechnen.
- 3) *Interaktionsbewusste Modelle* berücksichtigen die gegenseitige Beeinflussung mehrerer Fahrzeuge, was insbesondere in hochgradig interaktiven Verkehrsräumen (z.B. an Kreuzungen) relevant ist. Die Interaktion kann durch Regeln und typische Verhaltensweisen der Kooperation oder auch den gegenseitigen Austausch von Fahrzuständen oder Fahrtrajektorien berücksichtigt werden. Diesen Modelltyp zeichnet aufgrund der Vielzahl möglicher Interaktionen eine hohe Komplexität aus.

Weil die Prädiktionsmodelle der Klassen 2) und 3) zur Realisierung längerer Prädiktionshorizonte Informationen der Fahrerabsicht verarbeiten, werden sie auch als Systeme der Fahrerabsichtserkennung bezeichnet. Allgemein ist der Begriff Absicht als Sequenz von Handlungen, die ein Akteur vollzieht, um ein Ziel zu erreichen, definiert; darauf aufbauend konkretisieren Casas, Luo & Urtasun [49] den Begriff der Fahrerabsicht im Kontext des Verhaltens von Verkehrsteilnehmern: die Fahrerabsicht kann sowohl durch eine Kombination diskreter „high level“-Verhalten als auch durch eine kontinuierliche Trajektorie der zukünftigen

Bewegung dargestellt werden. Diese beiden Ausprägungen sind allgemein als Manöver- und Trajektorienprädiktion bekannt. Beispiele für „high level“-Verhalten sind das Beibehalten der Fahrspur, ein Linksabbiegen oder der Spurwechsel nach rechts. Für eine kontinuierliche Trajektorie der zukünftigen Bewegung werden häufig die relativen Positionskoordinaten des Fahrzeugschwerpunkts oder eine Kombination relevanter fahrdynamischer Zustandsgrößen, z.B. Längs- und Querschleunigung, verwendet.

Je nach Anwendung in Fahrerassistenzsystemen oder dem hochautomatisierten Fahren ist die Fahrerabsichtserkennung für einen bestimmten Prädiktionshorizont von Interesse, der zwischen 3 s [49], meist 6 s [50–52], bis hin zu 10 s [53] liegt. Entsprechend des Drei-Ebenen-Modells der Fahraufgabe von Donges behandeln Systeme zur Fahrerabsichtserkennung damit die Bahnführungsebene [14].

Ein Großteil der Forschung zur Fahrerabsichtserkennung ist durch das hochautomatisierte Fahren mit PKW motiviert. Die autonomen Agenten müssen die Handlungen der sie umgebenden manuell gelenkten Fahrzeuge – und anderer Verkehrsteilnehmer wie z.B. Fußgänger – antizipieren, um sicher planen und agieren zu können. Entsprechend beschäftigen sich viele Ansätze in der Forschung mit der „Außensicht“ auf andere Verkehrsteilnehmer, was sich z.B. bei den Themen der Sensierung und Interaktion mit der Umgebung bemerkbar macht. Sie unterscheiden sich darin von der in dieser Arbeit anvisierten Fahrerabsichtserkennung in Form einer Trajektorienprädiktion des Ego-Fahrzeugs („Innensicht“). Die entsprechenden Unterschiede ausgeklammert, treffen viele Aspekte der Untersuchungen im Stand der Forschung jedoch auf beide Problemstellungen zu.

Der Schwerpunkt aktueller Forschungsaktivitäten der Fahrerabsichtserkennung im Allgemeinen und damit auch der Trajektorienprädiktion liegt im Bereich der manöverbasierten und interaktionsbewussten Modelle. Dabei werden flächendeckend Methoden des maschinellen Lernens eingesetzt, bei denen die Algorithmik teilweise oder vollständig anhand realer Datensätze gelernt wird. Am populärsten sind „deep learning“ Ansätze, eine Unterkategorie des maschinellen Lernens, bei der mehrschichtige neuronale Netze (NN) verwendet werden.

Mozaffari et al. [54] geben in ihrem Review einen umfassenden Überblick zu NN-basierten Ansätzen der Fahrerabsichtserkennung. Am häufigsten sind die Klasse der rekurrenten NN (RNN) anzutreffen, die gut für die Verarbeitung von Zeitreihendaten geeignet sind (Grundlagen dazu in Abschnitt 3.2). Weil sich eine Fahrsituation oft erst aus dem zeitlichen Zusammenhang der Fahrzustände ergibt, ist dies vorteilhaft für die Extraktion von Information über die Fahrerabsicht. Hingegen sind RNN schlecht in der Verarbeitung räumlicher Informationen, was insbesondere für die Positionsinformationen verschiedener Verkehrsteilnehmer in dichten

Verkehrsräumen von Bedeutung ist [55]. Zu diesem Zweck werden bevorzugt Convolutional-NN [49, 52] eingesetzt, die gut zur Berücksichtigung mehrdimensionaler Zusammenhänge (z.B. in Form von Positionsdaten, Karteninformation aus Bildern, Rohdaten bildgebender Sensoren) geeignet sind. Außerdem kommen Graph-NN [56] zur Anwendung, die Vorteile in der Darstellung von Interaktionen zwischen Verkehrsteilnehmern besitzen, oder es werden Kombinationen aller genannten NN-Typen [50] eingesetzt.

Die verschiedenen NN-basierten Methoden können hinsichtlich der Repräsentation der Fahrerabsicht unterschieden werden [54]. Das Ausgeben einer zukünftigen Manöverklasse hat einen geringen Rechenaufwand, deckt aber nur vorab definierte spezifische Fahrsituationen ab, weil die Manöverklassen in den Trainingsdaten annotiert sein müssen. Dies ist zeitaufwendig und fehleranfällig und führt insbesondere bei komplexen Fahrmanövern zu Problemen, weil diese nur uneindeutig zugeordnet werden können oder weitere Manöverklassen definiert werden müssen [55]. Die Regression der zukünftigen Fahrzeugbewegung in Form einer Positionstrajektorie liefert hingegen deutlich detailliertere Information. Hierbei wird nochmals zwischen uni- und multimodaler Trajektorienprädiktion unterschieden.

Bei einer unimodalen Prädiktion berechnet das NN eine wahrscheinlichste zukünftige Fahrtrajektorie bzgl. der gegenwärtigen Situation (z.B. in [53]). Dies ist einfach umzusetzen, widerspricht aber der eigentlichen Natur der Problemstellung, weil das Fahren eines Fahrzeugs multimodal ist, d.h. es können zu einem Zeitpunkt verschiedene Möglichkeiten des zukünftigen Verhaltens existieren [54]. Durch die unimodale Vereinfachung besteht deshalb die Gefahr, dass ein mittleres Verhalten erlernt wird, welches in Realität nicht vorkommt. Zur Beseitigung dieses Konflikts gibt es Erweiterungen, in denen die unimodale Prädiktion durch eine vorab bestimmte zukünftige Manöverklasse konditioniert wird. Damit ergibt sich jedoch wieder die Problematik vorab bekannter und definierter Manöverklassen, die in den Daten annotiert sein müssen. Benterki et al. [51] fokussieren sich beispielsweise auf die Prädiktion von Spurwechsel-manövern auf mehrspurigen Schnellstraßen und definieren die drei querdynamischen Manöverklassen „Spur beibehalten“, „Spurwechsel nach links“ und „nach rechts“, um eine unimodale Trajektorienprädiktion zu konditionieren.

Multimodale Prädiktionsmodelle geben mehrere Trajektorien mit dazugehöriger Auftretenswahrscheinlichkeit aus, was dem Naturell der Verhaltensprädiktion am besten entspricht. Die Modelle besitzen jedoch die höchste Komplexität bzgl. Rechenaufwand und Training [54]. Werden die unterschiedlichen Moden der Prädiktion vorab definierten Manöverklassen zugeordnet (sogenannte statische Moden), entstehen wieder die bereits genannten Schwierigkeiten durch Datenannotation. Die statischen Moden „Beschleunigung“, „Bremsen“, „Spurwechsel“, „Abbiegen“, „Stoppen“ und „Folgen“ werden z.B. im multimodalen

Prädiktionsmodell von Berkemeyer et al. [50] verwendet, um die Trajektorie in Kreuzungsszenarien vorherzusagen. Deo & Trivedi [57] kombinieren drei querdynamische und zwei längsdynamische Manöverklassen, deren Einzelprädiktionen durch Multiplikation mit geschätzten Klassenwahrscheinlichkeiten in die prädizierte Trajektorie einfließen. Beim Einsatz dynamischer Moden hingegen muss keine Annotation von Klassen im Trainingsdatensatz stattfinden. Eine vorgegebene Anzahl von Moden wird stattdessen während des Modelltrainings durch das NN selbst gelernt. Es besteht hierbei aber die Herausforderung, dass die Möglichkeit multipler Moden tatsächlich durch das NN-Modell ausgenutzt wird. Cui et al. [52] haben in der Verwendung dynamischer Moden für die Trajektorienprädiktion in Kreuzungsszenarien eine beste Anzahl von drei festgestellt, die sich im Training als die Manöver Geradeausfahrt, Links- und Rechtsabbiegen ausgeprägt haben.

Nachdem die drei grundlegenden Ebenen der Trajektorienprädiktion sowie verschiedene Arten der manöver- und interaktionsbasierten Fahrerabsichtserkennung mittels NN-Methoden beschrieben wurden, werden im Folgenden motorradspezifische Untersuchungen in diesem Themenfeld vorgestellt. Forschungstätigkeiten, die sich ausschließlich mit der Längsdynamik des Motorrads beschäftigen, werden nicht betrachtet.

Das CMC [22] stellt ein Gütemaß für die Bewertung der Trajektorienprädiktion eines Motorrads vor, welches auch in dieser Arbeit als Metrik verwendet wird (siehe Abschnitt 7.2), und leitet für dieses einen Zielwert bzgl. einer C-ITS-Kollisionswarnfunktion in Abbiege- manövern her. Anschließend wird mittels Simulation der Manöver aufgezeigt, dass der erforderliche Prädiktionshorizont von 6,5 s mit den physikalischen Prädiktionsmodellen aus dem Stand der Technik unerreichbar ist. Die Autoren schlagen für die weitere Forschung vor, Informationen zu Fahrerabsicht und Situationskontext (z.B. Karteninformation oder Historie der Messdaten) einzubeziehen sowie Methoden des maschinellen Lernens einzusetzen.

Wirth et al. [58] verwenden ein zweiradspezifisches Kinematikmodell zur Vorhersage des physikalisch sinnvollen Aufenthaltsraums von Fahrradfahrern. Bis zu einem Prädiktionshorizont von 1,5 s wird dieses physikalische Prädiktionsmodell ausgewertet. Für weitere Vorausschauzeiten wird der Einsatz von manöver- oder interaktionsbasierten probabilistischen Prädiktionsmodellen vorgeschlagen. Bei diesen kann die Ausgabe des zweiradspezifischen Kinematikmodells zur Plausibilisierung prädizierter Trajektorien eingesetzt werden

Scherer & Basten [41] beobachten eine Fahrer- und Manöverspezifität in den Rollwinkel- und Geschwindigkeitsverläufen des Motorrads beim wiederholten Durchfahren einer Kurve in einer Probandenstudie. Anschließend approximieren sie die Verläufe beider Fahrdynamikgrößen erfolgreich mittels parametrierbarer mathematischer Funktionen für die drei Manöversegmente „Einrollen“, „stationäre Kurvenfahrt“ und „Ausrollen“. Die fahrerspezifischen gefitteten Funktionen können schließlich zur Trajektorienprädiktion verwendet werden, wenn der Verlauf der vorausliegenden Strecke bekannt ist.

Es wird die Hypothese aufgestellt, dass dieses Vorgehen durch das Hinzufügen von kurvenindividuellen Parametern auf beliebige Straßenverläufe generalisierbar ist, wenn ausreichend Fahrdaten zum Fitting der Parameter verfügbar sind. Dieser manöverbasierte Ansatz zur Trajektorienprädiktion in Kurven kommt dabei ohne Interpretation der Fahrerabsicht zur Laufzeit aus, denn diese Informationen sind in den gefitteten fahrer- und manöverspezifischen Parametern enthalten.

Die erste grundlegende Annahme, dass sich Motorradfahrer unabhängig von Fahrzeug und Tagesform in einer bestimmten Kurve ähnlich verhalten, wurde anhand eines Probanden in einem Fahrversuch im realen Straßenverkehr getestet [59]. Während kein verändertes Fahrerverhalten beim Wechsel der Motorräder festgestellt wurde, gab es einen Einfluss der Tagesform, der mit unterschiedlicher Witterung und Training des Fahrers (Saisonbeginn versus Mitte der Fahrsaison) begründet wurde.

Die zweite grundlegende Annahme zur Übertragbarkeit der kurvenspezifischen Parameter, d.h. gleiches Fahrerverhalten in Kurven ähnlicher Charakteristik, wurde noch nicht untersucht. Auch die realisierte Prädiktion des Geschwindigkeitsverlaufs in Kurven mittels manöver- und fahrerindividueller Funktionen wird von den Autoren kritisch hinterfragt, denn diese ist im Vergleich zum Rollwinkelverlauf weniger stark an den Kurvenverlauf gekoppelt [41]. Besonders bei der Fahrt im realen Straßenverkehr kommen andere Verkehrsteilnehmer als Störgrößen hinzu und eine veränderte Fahrgeschwindigkeit wirkt sich wiederum auf den gefahrenen Rollwinkel aus.

Hecker et al. [20] entwickeln ein Kurvenassistenzsystem, das anhand eines Optimal Control Ansatzes die optimale vorausliegende Fahrtrajektorie berechnet. Das zugrundeliegende Systemmodell beinhaltet ein einfaches Fahrdynamikmodell des Motorrads, welches den Längs- und Gierruck als Eingangsgrößen hat. Überschreitet der Längsruck in der optimalen Trajektorie der Eingänge einen kritischen Schwellwert, wird eine Warnung an den Fahrer ausgegeben. Für die Optimierung werden der Krümmungs- und Steigungsverlauf sowie die Geschwindigkeitsbeschränkungen entlang der vorausliegenden Strecke als Randbedingungen benötigt. Diese

Informationen werden aus einer Karte bezogen. Die Lokalisierung in der Fahrspur und Schätzung des aktuellen Rollwinkels erfolgen mittels einer Kamera.

Der Ansatz ist als manöverbasiertes Modell zu bewerten, denn die Fahrerabsicht, der Fahrspur mit einer bestimmten Dynamik zu folgen, wird durch die Kostenfunktion und Randbedingungen in der Optimierung abgebildet. Informationen zu Fahrerverhalten oder Fahrereingaben in der aktuellen Fahrsituation werden aber nicht erfasst. Die Optimierung ermöglicht beliebig lange Prädiktionshorizonte, die nur durch die Rechenzeit limitiert werden. Für ein gezeigtes Beispiel-Kurvenmanöver wird eine erforderliche Vorausschaudistanz von mindestens 100 m genannt; die optimale Trajektorie verhält sich in diesem bzgl. der Geschwindigkeit ähnlich wie der echte Fahrer, die Fahrspurbreite wird jedoch stärker ausgenutzt, weshalb ein abweichender Rollwinkelverlauf prädiziert wird.

Immel [60] entwirft ein Modell zur multimodalen Trajektorienprädiktion von Fahrrädern. Die Verwendung einer variablen Anzahl von Knoten in einem Graph-NN macht es möglich, dass immer genau so viele Moden prädiziert werden, wie es mögliche Pfade im vorausliegenden Streckenabschnitt gibt, z.B. zwei an eine T-förmigen Kreuzung. Neben der Zeithistorie von Dynamiksignalen gehen dazu auch Karteninformationen in das Modell ein. Eine weitere Besonderheit des Ansatzes ist, dass das NN selbst nicht direkt Positionen, sondern Trajektorien der Längsbeschleunigung und Gierrate prädiziert, welche anschließend durch ein kinematisches Modell in eine Positionstrajektorie übersetzt werden. Dadurch ergeben sich glattere und damit realistischere Fahrtrajektorien.

Zusammengefasst wird die Trajektorienprädiktion vor allem im Kontext des autonomen Fahrens erforscht, wobei zur Erreichung langer Prädiktionshorizonte überwiegend manöver- oder interaktionsbasierte Ansätze gewählt werden. Diese verarbeiten Informationen zur Fahrerabsicht, indem u.a. die Zeithistorie von Messsignalen interpretiert wird. Zum Einsatz kommen häufig tiefe NN, wobei RNN für die Interpretation von Zeitreihendaten besonders geeignet sind; diese Klasse von NN-Methoden wird in Abschnitt 3.2 vertieft vorgestellt.

Im Bereich der Trajektorienprädiktion für Motorräder wird durch die Arbeit des CMC gezeigt, dass die einfachen physikalischen Bewegungsmodelle keine ausreichende Prädiktionsgüte für zukünftige vernetzte Assistenzsysteme erreichen. Ein physikalischer Ansatz der Trajektorienprädiktion, der neuartige Messgrößen des Motorrads, wie z.B. querdynamische Fahrereingaben oder Zustandsgrößen der Lenkung, berücksichtigt, ist nicht bekannt. Mit Untersuchungen zum querdynamischen Übertragungsverhalten des Motorrads in Kapitel 5 wird das Potenzial von Fahrereingaben für die physikalische Trajektorienprädiktion abgeschätzt.

Alle drei vorgestellten Untersuchungen der motorradspezifischen und manöverbasierten Trajektorienprädiktion verwenden Karteninformation, um Information der Fahrerabsicht zum aktuellen Zeitpunkt zu erhalten. In der Methode von Scherer & Basten [41] fließen zudem statistische Muster des fahrer- und manöverspezifischen Verhaltens ein. Die Verwendung eines RNN-basierten Prädiktionsmodells für die motorradspezifische Trajektorienprädiktion, welches sowohl die Signalhistorien der Fahrzustände als auch die der querdynamischen Fahrer-eingaben interpretiert, ist nicht im Stand der Forschung vertreten. Solch ein Algorithmus wird in Kapitel 7 realisiert und orientiert sich an den Forschungsaktivitäten im Bereich des autonomen Fahrens im PKW. Es ist keine Forschungsarbeit bekannt, die eine motorrad-spezifische Trajektorienprädiktion auf einem repräsentativen, d.h. in Fahrstrecke und Fahrern diversen, Datensatz untersucht.

3 Grundlagen

Die in dieser Arbeit angestrebte motorradspezifische Algorithmik zur lateralen Trajektorienprädiktion soll querdynamisch wirksame Fahrereingaben und Zustandsgrößen der Lenkung berücksichtigen. Deshalb ist eine Einführung in die spezielle, im Vergleich zum PKW stark unterschiedliche, Fahrdynamik des Zweirads in Kurvenfahrt in Abschnitt 3.1 sinnvoll.

Abschnitt 3.2 erläutert die Methode neuronaler Netze (NN) allgemein und vertieft sich anschließend in der Funktionsweise und Anwendung rekurrenter neuronaler Netze (RNN) zur Verarbeitung von Zeitreihendaten, denn dieser spezielle Typ eines NN wird in Kapitel 7 für die manöverbasierte laterale Trajektorienprädiktion eingesetzt.

3.1 Zweiraddynamik

Das Verständnis für die Fahrdynamikgrößen und das Fahrverhalten des Motorrads in Kurvenfahrt ist für die Interpretation der Ergebnisse im Laufe der Arbeit wichtig. Es werden deshalb zunächst die Kinematik und das Kippverhalten des Zweirads erläutert. Weiterhin werden die Dynamik in Kurvenfahrt sowie – im Hinblick auf die neuartigen Messgrößen, die im Fokus der Arbeit stehen – die Lenkdynamik und querdynamischen Fahrereingaben beschrieben.

Die Diskussion unterschiedlicher Ansätze der Fahrdynamiksimulation und deren diverse Herausforderungen begründen die Notwendigkeit von Fahrversuchen mit einem Versuchsmotorrad.

3.1.1 Kinematik und Kippverhalten

Die Bewegungen des Zweirads im Raum sind entsprechend der DIN ISO 8855 [61] definiert. In einer schematischen Skizze des Zweirads in Abbildung 3.1 sind die drei wichtigsten Koordinatensysteme (KS) sowie bedeutende Zustandsgrößen der Querdynamik eingezeichnet. Das horizontierte Fahrzeug-KS (XYZ) hat den Ursprung im Radaufstandspunkt des nicht lenkbaren Hinterrads, die Z -Achse zeigt in Richtung der Erdbeschleunigung nach oben und die X -Achse ist orthogonal zur Hinterradachse in Fahrtrichtung ausgerichtet. Die bei Kurvenfahrt entstehende Orientierungsänderung des KS um die Z -Achse wird als horizontierte Gierrate $\dot{\psi}_{\text{hor}}$ bezeichnet, die absolute Orientierung als Gierwinkel ψ .

Das Fahrzeug-KS ($X_v Y_v Z_v$) ist fest mit dem Hauptrahmen verbunden und hat den Ursprung meist im Fahrzeugschwerpunkt. Seine Orientierung gegenüber dem horizontierten Fahrzeug-

KS ist durch Drehung um die zwei verbleibenden Eulerwinkel Nickwinkel θ und Rollwinkel φ in genannter Reihenfolge definiert (ausgehend von einem globalen KS ist ψ der erste Eulerwinkel). Die Orientierungsänderungen um die X_V -, Y_V - und Z_V -Achse werden als Rollrate $\dot{\varphi}$, Nickrate $\dot{\theta}$ und Gierrate $\dot{\psi}$ bezeichnet.

Durch eine Drehung des Fahrzeug-KS um den Betrag des Nachlaufwinkels ϵ in negativer Richtung um die Y_V -Achse ergibt sich die Orientierung der Lenkachse Z_S . Um diese Achse sind Lenkwinkel δ und -rate $\dot{\delta}$ definiert. Das Lenk-KS ($X_S Y_S Z_S$) ist fest mit den gelenkten Baugruppen Vorderrad, Vorderradführung und Lenker verbunden und hat den Ursprung meist in dessen Summenschwerpunkt.

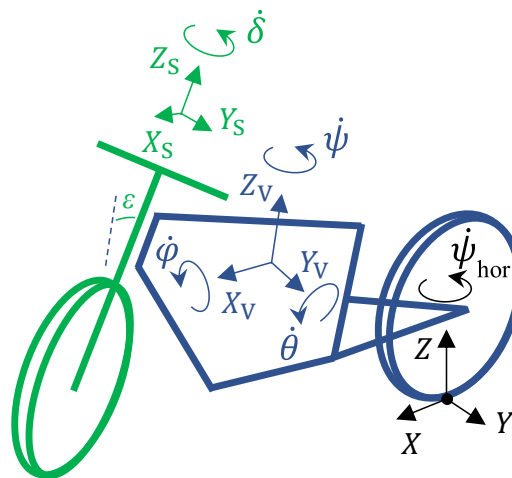


Abbildung 3.1: Definition von horizontiertem und fahrzeugfestem Fahrzeugkoordinatensystem sowie Lenkkoordinatensystem entsprechend DIN ISO 8855 [61]. Bedeutende Winkelgeschwindigkeiten sind bzgl. der jeweiligen Bezugskordinatensysteme eingezeichnet. Der Nachlaufwinkel ϵ ist markiert.

Das Kippverhalten ist essentiell für die Fahrdynamik des Zweirads. Für dessen Erläuterung wird das Zweirad zunächst als ein Starrkörper, d.h. ohne Lenksystem und mit zwei punktförmigen Aufstandspunkten anstelle von Vorder- und Hinterrad, betrachtet. Entsprechend der Mechanik besitzt ein Starrkörper im dreidimensionalen Raum insgesamt sechs Freiheitsgrade, drei translatorische und drei rotatorische. Die Aufstandspunkte besitzen die Eigenschaft, dass sie ausschließlich Kräfte in die drei Raumrichtungen übertragen können, senkrecht zur Fahrbahn als Aufstandskraft und in Fahrbahnebene als Längs- und Querkräfte. In den Kontaktpunkten werden keine Momente übertragen³. Damit werden dem Starrkörper zwar alle drei translatorischen, jedoch nur zwei der drei rotatorischen Freiheitsgrade gesperrt. Es verbleibt, dass der Starrkörper um die Achse kippen kann, welche durch die Verbindung beider

³ In Realität bildet der Reifen einen Latsch und damit eine Aufstandsfläche anstatt eines -punkts aus, weshalb im begrenzten Maße auch Momente übertragen werden. Insbesondere um die Achse senkrecht zur Fahrbahn entsteht in Kurvenfahrt das sogenannte Reifentorsionsmoment zwischen Reifen und Fahrbahn [62].

Aufstandspunkte gebildet wird. Dies ist die X - bzw. X_V -Achse in Abbildung 3.1 und damit die Rollachse des Motorrads. Das so weit vereinfachte Zweirad verhält sich wie ein inverses Pendel und besitzt in der aufrechten Position eine instabile Ruhelage, d.h., dass kleine Auslenkungen aus der aufrechten Position ein Umkippen verursachen. Das Einwirken externer Kräfte oder Momente ist erforderlich, um diese Ruhelage zu stabilisieren.

Die Erweiterung des stark vereinfachten Zweiradmodells mit einem Lenksystems mit Nachlauf (z.B. durch den Nachlaufwinkel ϵ , wie in Abbildung 3.1), d.h. einem Abstand zwischen virtuellem Durchstoßpunkt der Lenkachse mit der Fahrbahn und Aufstandspunkt des gelenkten Rads, ermöglicht die Stabilisierung der instabilen Ruhelage durch den Fahrer. Dieser nutzt aus, dass eine Lenkbewegung zugleich eine laterale Verschiebung des Systemschwerpunkts verursacht. So gelingt es geübten Fahrern, dass sie ein stillstehendes Zweirad mit ständigen Lenkbewegungen – meist unterstützt durch Schwerpunktverlagerung des Körpers – aufrecht balancieren.

Die Stabilisierungstätigkeit des Zweiradfahrers wurde in diversen Arbeiten untersucht [63–65]. In einfachen Worten muss in allen stationären Fahrsituationen sichergestellt sein, dass sich die Verbindungslinie der Radaufstandspunkte und der Summenkraftvektor durch den Schwerpunkt des Fahrer-Fahrzeug-Gesamtsystems schneiden. Anhand dieser Bedingung wird deutlich, warum ein Zweirad Kurven nur mit Schräglage durchfahren kann, denn unter Einwirkung der Querbeschleunigung ergibt sich – in Abhängigkeit der Schwerpunkthöhe über der Fahrbahn – ein nicht mehr senkrecht wirkender Summenkraftvektor. Diesem wird durch die Schräglage des Fahrzeugs nach kurveninnen Rechnung getragen. Abbildung 3.2 stellt das beschriebene Gleichgewicht aus angreifenden Kräften und Schräglage für eine stationäre Kurvenfahrt vereinfacht in der Y - Z -Ebene dar. Hier schneidet der im Schwerpunkt wirkende Summenkraftvektor F aus Vertikalkraft F_z und Querkraft F_y den Radaufstandspunkt.




Abbildung 3.2: Schnittpunkt von Summenkraftvektor und Reifenaufstandslinie (-punkt in Y - Z -Ebene) ermöglicht die stationäre Kurvenfahrt.

In Realität kann der Schnittpunkt von Radaufstandslinie und Summenkraftvektor nicht exakt durch den Fahrer eingestellt werden, weil ständige Störungen (z.B. Fahrbahnanregungen) auf das Zweirad einwirken. Vielmehr besteht eine periodische Stabilisierungsbewegung um diesen

Zustand herum, welche sich in kleinen Schwankungen von Rollwinkel und -rate äußert; es liegt damit kein ideal stationärer, sondern ein quasistationärer Fahrzustand der Querdynamik vor.

Ist ein Zweirad in Fahrt, dann bestehen – zusätzlich zu den bis hierhin beschriebenen kinematischen Mechanismen – dynamische Effekte, welche die Stabilisierung des Kippverhaltens vereinfachen können. Diese werden im folgenden Abschnitt erläutert.

3.1.2 Dynamikmodelle

Mit üblichen Auslegungen der Lenkkinematik eines Zweirads treten mehrere stabilisierende Effekte auf. Zum einen stabilisiert der Nachlauf des Vorderrads in Fahrt den Lenkwinkel, weil die Reifenseitenkräfte aus Auslenkungen der Lenkung rückstellend wirken. Zum anderen verhält es sich bei einer günstigen Schwerpunktlage des Lenksystems so, dass sich das Vorderrad in Richtung einer Rollbewegung des Zweirads eindreht; dies bewirkt den Aufbau einer Reifenseitenkraft, die wiederum der verursachenden Rollbewegung entgegenwirkt und den Lenkwinkel rückstellt. Der Mechanismus der Stabilisierung durch eine Lenkerdrehung in Richtung der Rollbewegung wird auch als „steer-into-the-fall“ bezeichnet.

Mit zunehmender Fahrgeschwindigkeit leistet außerdem der gyroskopische Effekt⁴ aus rotierenden Massen einen bedeutenden Beitrag zur Stabilisierung der Kippmode des Zweirads. Am sich drehenden Vorderrad löst das gyroskopische Moment, welches aufgrund einer Rollbewegung entsteht, ebenfalls den stabilisierend wirkenden „steer-into-the-fall“ Mechanismus aus. Im Vergleich dazu haben die gyroskopischen Momente aufgrund der rotierenden Massen von Motor, Getriebe, Endantrieb und Hinterrad einen deutlich geringeren Effekt auf die Stabilisierung der Kippmode.

Um die beschriebenen Effekte in einem Modell abzubilden, kann das Zweirad z.B. durch vier Starrkörper dargestellt werden: zwei Räder (ohne Reifenbreite), ein Hauptrahmen (hier wird der Fahrer zugeschlagen) und die gelenkte Vorderradführung (als Lenksystem bezeichnet). Zwischen den vier Körpern besteht je ein rotatorischer Freiheitsgrad um beide Radachsen und die Lenkachse. Das resultierende nichtlineare Modell der Querdynamik ist entsprechend seines Entwicklers als Whipple-Modell bekannt. Es kann um Fahrzustände in Lenk- und Rollwinkel linearisiert werden, um anhand der Eigenmoden des linearen Systems die Stabilität des Zweirads zu untersuchen [66]. Neben der Kippmode um die Rollachse besitzt das Zweirad noch zwei weitere querdynamische Eigenmoden, die erst bei höheren Geschwindigkeiten hervortreten: die Pendel- (~ 3 Hz) und Fluttermode (~ 5-9 Hz) [67]. Weil sich die Eigenmoden

⁴ Wird eine rotierende Masse um eine senkrecht zur Rotationsachse stehende Achse gedreht, dann entsteht ein Reaktionsmoment um eine auf beiden Achsen orthogonal stehende Achse. Das gyroskopische Moment wirkt entsprechend der „rechten Hand Regel“

von Quer- und Vertikaldynamik in Kurvenfahrt vermischen, sind Stabilitätsuntersuchungen auch in unterschiedlichen Fahrzuständen des Rollwinkels durchzuführen.

Eine insbesondere für Motorräder interessante Erweiterung des Whipple-Modells ist die Berücksichtigung der realen Reifenbreite, z.B. durch Modellierung kreisförmiger Reifenquerschnitte mit definierten Radien. Dadurch kommt es zu sich verändernden Reifenaufstandspunkten unter Roll- und Lenkbewegung [68]. Insbesondere bei Untersuchungen im Lenksystem, z.B. hinsichtlich des Lenkmoments in Kurvenfahrt, hat dieser Effekt großen Einfluss.

Aktuell ist der Einsatz von Mehrkörpersimulations-Software Stand der Technik für die Fahrdynamiksimulation von Zweirädern. In diesen werden die einzelnen Komponenten der Radaufhängung und Steifigkeitseigenschaften der Baugruppen berücksichtigt. Ebenfalls können die Kopplung des Fahrers mit dem Hauptrahmen und Lenksystem sowie verschiedene Fahrerbewegungen detailliert dargestellt werden, wenn dieser, dargestellt durch einen oder mehrere Starrkörper, an mehreren Gelenken am Motorrad angebunden wird. Diese Modelle haben typischerweise zwischen zehn und 30 Freiheitsgrade. Eine gute Übersicht wird im Review von Bruni et al. [69] gegeben.

Bereits im Whipple-Modell können Reifenmodelle für eine realistischere Darstellung des Fahrbahn-Fahrzeug-Kontakts eingesetzt werden. Mit Ansätzen wie linearen Steifigkeiten, Bürsten oder der Magic-Formula sind die gleichen Modellierungen wie in der Simulation mehrspuriger Fahrzeuge üblich. Ein wichtiger Unterschied besteht aber in der deutlich vergrößerten Relevanz der Sturzsteifigkeit für Motorradreifen. Aufgrund der Schräglage in Kurvenfahrt entsteht der Großteil der Seitenführungskraft durch Reifensturz und nur ein kleiner, korrigierender Anteil aus Schräglaufwinkel; man spricht von idealem neutralen Reifenverhalten, wenn der für eine konstante Kurvenfahrt erforderliche Schräglaufwinkel an beiden Reifen 0° beträgt, die Seitenkräfte demnach ausschließlich aus Reifensturz kommen [68]. Der geringe Schräglaufwinkelbedarf von Motorrädern trägt dazu dabei, dass diese in Kurvenfahrt deutlich geringere Lenkwinkel – bei Geschwindigkeiten größer 30 km/h typischerweise weniger als 5° – benötigen als Mehrspurfahrzeuge.

3.1.3 Lenkdynamik

Im Hinblick auf die Untersuchung querdynamischer Fahrereingaben in Kapitel 5 soll auf die besondere Lenkdynamik von Zweirädern in transients Kurvenfahrt, d.h. bei Einfahrt in oder Ausfahrt aus einer Kurve, eingegangen werden.

In Abschnitt 3.1.1 wurde das Modell des inversen Pendels zur Erläuterung des Kippverhaltens und der Notwendigkeit von Schräglage in Kurvenfahrt eingeführt. Soll ein solches Pendel aus

einer Geradeausbewegung in eine stationäre Kurventrajektorie überführt werden (Schräglage nach kurveninnen zur Erfüllung der stationären Bedingung, wie in Abbildung 3.2), so muss sein Fußpunkt zunächst entgegen der angestrebten Richtung (nach kurvenaußen) beschleunigt werden, um eine initiale Rollbewegung nach kurveninnen zu bewirken. Nur so kann die stationäre Schräglage und damit die Kurventrajektorie erfolgreich eingestellt werden. Ein solches nicht-minimalphasiges Systemverhalten ist gleichermaßen am Zweirad vorzufinden. Um eine Rollbewegung in Kurvenrichtung einzuleiten, muss ein Lenkeinschlag nach kurvenaußen eingebracht werden (engl. countersteering). Kinematisch bewirkt dieser die Verschiebung der Radaufstandslinie nach kurvenaußen (engl. outracking), und damit eine relative Schwerpunktverlagerung nach kurveninnen. Dynamisch entsteht durch das Countersteering ein Schräglaufwinkel am Vorderrad, der den Aufbau einer Seitenkraft nach kurvenaußen bewirkt; diese Seitenkraft verstärkt die Rollbewegung des Zweirads nach kurveninnen. Sobald das Zweirad in Schräglage geht, überwiegen in Richtung kurveninnen wirkende Seitenkräfte aus dem Reifensturz den initialen Impuls aus Countersteering und Outtracking, das Zweirad baut Querschleunigung in Kurvenrichtung auf und die Einrollbewegung nach kurveninnen wird abgefangen.

Das beschriebene nicht-minimalphasige Verhalten kann anhand der gemessenen Fahrdynamikgrößen eines Einlenkvorgangs mit einem Motorrad in Abbildung 3.3 nachvollzogen werden. Wie an den positiven Werten des Rollwinkels φ zu erkennen ist, handelt es sich um eine Rechtskurve. Zum Zeitpunkt 0,4 s bringt der Fahrer ein positives, bzgl. der Rechtskurve nach kurvenaußen wirkendes, Lenkmoment M_Z auf. Infolgedessen wird das Vorderrad um ein δ von rund $0,5^\circ$ nach kurvenaußen eingeschlagen. Kurz darauf ist die beginnende Einrollbewegung in Richtung der Kurve auch im ansteigenden φ sichtbar. Im Verlauf von δ in Abbildung 3.3 ist das Countersteering des Vorderrads blau hervorgehoben. Bis zum Ende des Einrollens zum Zeitpunkt 2 s nimmt δ schließlich den für die stationäre Kurvenfahrt notwendigen Wert an, M_Z bleibt hingegen während des gesamten Einlenkvorgangs nach kurvenaußen gerichtet.

Mit einer Rollratenamplitude von fast 50 %/s zeigt Abbildung 3.3 ein sportliches Einlenken. Bei niedrigdynamischen Fahrmanövern ist der Effekt des Countersteering hingegen so klein, dass er aufgrund von Störungen und der Stabilisierungsarbeit des Fahrers nicht mehr im Lenkwinkel- und Lenkmomentsignal erkennbar ist. Ein Erklärungsansatz hierfür ist, dass aufgrund der diversen Störungen, die im realen Straßenverkehr auf die Lenk- und Rolldynamik einwirken, keine aktive Lenkeingabe zum Einleiten des Outtrackings notwendig ist, sondern dass Fahrer durch eine bewusst nicht ausgeregelte Störung einen niedrigdynamischen Einlenkvorgang initiieren [70].

Die Notwendigkeit des Countersteerings zur Einleitung eines querdynamischen Manövers bedingt, dass das Motorrad trotz eines deutlichen Gewichtsvorteils in transienten Manövern meist weniger dynamisch reagieren kann als ein PKW [67].




Abbildung 3.3: Fahrdynamiksignale bei Einfahrt in eine Rechtskurve, gefiltert mit einem 5 Hz Tiefpassfilter. Das Countersteering des Vorderrads ist im Lenkwinkelsignal blau hinterlegt.

Im Zusammenhang mit dem Einleiten einer Kurve wird oftmals vom Lenkimpuls gesprochen. In Abbildung 3.3 ist im Verlauf von M_z zu erahnen, was damit gemeint ist: während des Einrollens wird zwischen 0,6 und 1,2 s ein höheres Lenkmoment gestellt als später während der Phase konstanter Kurvenfahrt. Dass diese impulsförmige Erhöhung des Lenkmoments über den Moment des Outtrackings im Lenkwinkel hinaus nach kurvenaußen gerichtet ist, hat mit den zahlreichen Kräften und Momenten zu tun, welche auf das Lenkmoment des Motorrads einwirken. Die unterschiedlichen Beiträge von Massenkräften, Trägheitsmomenten, Reifenkräften & -momenten sowie gyroskopischen Momenten während stationärer und transienter Querdynamik sind ausführlich in [71] beschrieben. In transienten querdynamischen Fahrmanövern – z.B. bei sportlicher Einfahrt in eine Kurve – dominiert das gyroskopische Moment des Vorderrads aufgrund der Rollbewegung das Lenkmoment und damit die Höhe des Lenkimpulses [72]; hierbei sind kleine Geschwindigkeiten ausgenommen. Es steigt proportional zu Geschwindigkeit und Rollrate, sodass hohe Lenkmomente notwendig sind, um schnelle Fahrzeugreaktionen des Motorrads zu erreichen. Besonders bei schneller Fahrt ist deshalb häufig die Kraft des Fahrers der limitierende Faktor bzgl. der Querdynamik in einem transienten Fahrmanöver [67].

Die für den Einlenkvorgang benötigte Schwerpunktverlagerung nach kurveninnen kann zusätzlich durch den Fahrer verstärkt werden, indem dieser seinen Körperschwerpunkt vor Beginn des Manövers quer zur Fahrtrichtung (Y_V -Achse) nach kurveninnen verlagert. Auch in

stationärer Kurvenfahrt bewirkt die Gewichtsverlagerung einen veränderten querdynamischen Fahrzustand. Damit besteht in der Fahrerbewegung eine zweite, unabhängige Eingangsgröße für die Querdynamik des Zweirads. Sie wird teilweise als Fahrerrollmoment ausgedrückt: das um die Rollachse wirkende Moment aufgrund der lateralen Verlagerung des Fahrerschwerpunkts. In den Untersuchungen zum querdynamischen Übertragungsverhalten des Versuchsmotorrads in Kapitel 5 wird die Bedeutung der Fahrerbewegung für die Kurvenfahrt ausführlich behandelt.

3.1.4 Problematik der Simulation

Sowohl simulative als auch experimentelle Untersuchungen zu Effektivität und Einfluss der querdynamischen Eingangsgrößen von Motorrädern wurden in Abschnitt 2.1 beschrieben. Dabei wurde auch auf die Problematik aufmerksam gemacht, dass keine validierten Fahrerregler für die Fahrdynamiksimulation existieren, die beide Eingangsgrößen realgetreu einsetzen. Daher ist es nicht sinnvoll, Untersuchungen zum Übertragungsverhalten von Fahrereingangsgrößen rein simulativ durchzuführen.

Eine nur teilweise simulative Methode besteht in der Nutzung eines Motorradsimulators, bei dem die Fahrdynamik (mittels Mehrkörpermodell) und Umgebung online simuliert und dem realen Fahrer visuell und mittels Motion Cueing auf einer Bewegungsplattform wiedergegeben wird. Dieser führt basierend auf den simulierten Reizen die Fahraufgabe aus. Es gibt bereits einen Motorradsimulator, in welchem sowohl Lenk- als auch Fahrerrollmomenteingaben berücksichtigt werden [73].

Theoretisch ermöglicht der Fahrsimulator sichere und wiederholbare Versuchsbedingungen für Forschung und Entwicklung. Allerdings bestehen noch drei hauptsächliche Herausforderungen, welche letztlich die Durchführung realer Fahrversuche für die Untersuchung querdynamischer Fahrereingaben motivieren:

- 1) Die Reifenmodellierung kann zahlreiche Umweltfaktoren und Eigenschaften, die das Reifenverhalten in Realität beeinflussen, nicht validiert wiedergeben. Insbesondere das Übertragungsverhalten der Lenkung des Motorrads ist sensitiv auf Reifenverhalten; ein untersuchtes Beispiel ist der Einfluss von Reifenverschleiß [74].
- 2) Störungen der Fahrstabilität, z.B. aufgrund von Fahrbahnanregungen oder Windeffekten, werden in der aktuellen Fahrdynamiksimulation nicht realistisch abgebildet. Dadurch fühlt sich die Regelungsaufgabe des Fahrers im Simulator bzgl. der Stabilisierung und in wenig dynamischen transienten Fahrmanövern anders an als in

Realität. Dass der Fahrsimulator das Fahrerverhalten deshalb verfälscht, kann nicht ausgeschlossen werden.

- 3) Die Immersion des Motorradfahrerlebnisses ist im Hinblick auf das Motion Cueing noch nicht soweit ausgereift, dass sich transiente Kurvenfahrt mit höherer Dynamik realistisch anfühlt. Insbesondere die Reize aus Gierrate und Querschleunigung sind schwierig zu ersetzen.

3.2 Neuronale Netze für Zeitreihendaten

Dieser Abschnitt erläutert die Grundlagen der maschinell gelernten Algorithmik, die in Kapitel 7 zur lateralen Trajektorienprädiktion eingesetzt wird. Zu Beginn wird eine kurze Einführung zu maschinellem Lernen und NN gegeben. Darin wird motiviert, dass für die Berücksichtigung zeitlicher Zusammenhänge zwischen Datenpunkten – die für die Prädiktion einer Fahrtrajektorie als bedeutend angesehen werden – besondere Klassen von NN eingesetzt werden. Der in dieser Arbeit eingesetzte RNN-Typ und das Vorgehen bei dessen Training werden anschließend ausführlich beschrieben.

3.2.1 Künstliche Neuronen und Zellen

Algorithmen des maschinellen Lernens zeichnen sich dadurch aus, dass sie auf Basis von Daten und ohne eine explizite Programmierung in einem mehrstufigen Lernprozess die Lösung einer spezifischen Aufgabe oder das Erkennen von Zusammenhängen realisieren. In Abhängigkeit der Problemstellung werden die Klassen „überwachtes Lernen“, „unüberwachtes Lernen“ und „Verstärkungslernen“ unterschieden. Im Hinblick auf eine Trajektorienprädiktion wird im Folgenden das überwachte Lernen betrachtet. Algorithmen dieser Klasse wird die Lösung einer spezifischen Aufgabenstellung anhand von Beispieldaten antrainiert [75]. Für die sogenannten Trainingsdaten ist das richtige bzw. angestrebte Verhalten bekannt, sodass sich der Algorithmus durch Optimierung an dieses annähern kann. Wird ein Algorithmus nach Abschluss des Trainings auf unbekannte Daten angewendet, spricht man von Inferenz. Im Allgemeinen erreichen Algorithmen des überwachten Lernens in der Inferenz bessere Performance, je größer die Menge und Qualität (z.B. Diversität) der Trainingsdaten ist.

Die bekannteste Klasse der Verfahren des maschinellen Lernens stellen NN dar. Bei diesen werden numerische Daten durch eine Vielzahl gleicher Bausteine, den künstlichen Neuronen, verarbeitet, die in mehreren Schichten hintereinander angeordnet sein können. Der Aufbau eines künstlichen Neurons sowie dessen Verknüpfung in mehreren Schichten sind in Abbildung 3.4 dargestellt. Jedes Neuron führt dabei einfache mathematische Operationen, nämlich

Multiplikationen mit Gewichten w_i (engl. weights) sowie die Addition eines Offsets b (engl. bias), auf eingehenden Daten aus. Nach dieser Verrechnung kann noch eine Aktivierungsfunktion a angewendet werden, bevor das Ergebnis an die Neuronen der folgenden Schicht weitergegeben oder, wenn das Neuron Teil der Ausgabeschicht ist, als Ergebnis des NN ausgegeben wird. Die Gewichte und Offsets aller Neuronen stellen die freien Parameter dar, die im Trainingsprozess optimiert werden. Dank der vielzähligen Vernetzung simpler Neuronen können NN universelle Funktionsapproximatoren darstellen, dessen sinnvolle Größe durch Rechenkapazität und Menge an Trainingsdaten begrenzt ist. NN mit mehreren verborgenen Schichten werden als tiefe NN (engl. deep learning) bezeichnet.

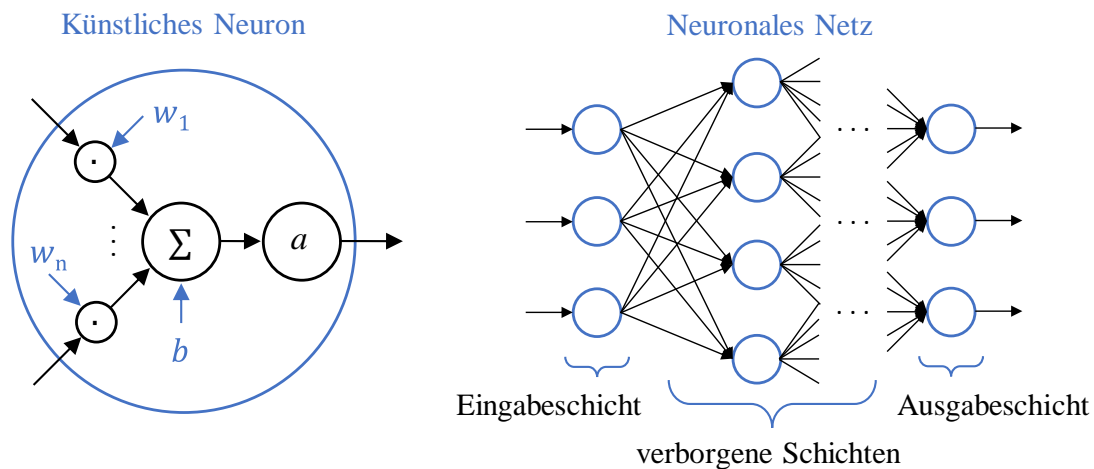


Abbildung 3.4: Aufbau eines künstlichen Neurons mit Gewichten (w_i , b) und Aktivierungsfunktion (a) sowie grundlegender Aufbau eines neuronalen Netzes mit Eingabe-, Ausgabe- und verborgenen Schichten (eigene Darstellung).

Klassische NN verarbeiten Daten zu jedem Zeitpunkt gleich, d.h. unabhängig von vorherigen Berechnungen. Sollen Muster über den Zeitverlauf von Daten berücksichtigt werden, so muss ein Zeitfenster von Interesse auf einmal in ein NN eingebracht werden. Dabei geht jedoch die Information der strikten zeitlichen Abfolge von Ereignissen in den Signalen verloren [76].

Rekurrente neuronale Netze (RNN) sind eine spezielle Form der NN, welche für die Verarbeitung von Zeitreihendaten besonders geeignet sind. Dem RNN wird eine zeitliche Sequenz von Daten Schritt für Schritt zugeführt, wobei je Zeitschritt die gleichen Rechenoperationen im Netzwerk durchgeführt werden. Dabei fließen neben den Daten des aktuellen Zeitschritts jedoch auch die Ergebnisse der vorherigen Rechenoperationen mit ein, die in sogenannten verborgenen Zuständen (engl.: hidden state) zwischengespeichert sind. Dank dieses Speichereffekts sind RNN in der Lage, die impliziten Informationen aus den zeitlichen Zusammenhängen der Datenpunkte zu berücksichtigen. Nachdem die gesamte Sequenz der Eingangsdaten in rekurrenten Rechenschritten verarbeitet wurde, wird der letzte verborgene Zustandsvektor als Ergebnis des RNN ausgegeben oder an nachgelagerte NN weitergegeben.

Die kleinste Einheit eines RNN wird Zelle genannt – analog dem Neuron im NN. Weit verbreitete Typen sind die „gated recurrent unit“ und „long short-term memory“ (LSTM) Zelle [76]. Mit ihrem speziellen Aufbau zielen sie darauf ab, die Probleme explodierender oder verschwindender Gradienten beim Training von RNN zu vermeiden. Beide Effekte können mit zunehmender Länge der Eingangssequenz auftreten und verhindern die erfolgreiche Optimierung des Netzwerkes, wodurch letztlich der Speichereffekt des RNN limitiert ist [76].

3.2.2 Long Short-Term Memory Zelle und Schicht

In Abbildung 3.5 ist der Aufbau einer LSTM-Zelle in Form eines Flussdiagramms des grundlegenden Berechnungsablaufs dargestellt. Die dazugehörigen Rechenvorschriften sind darunter in den Gleichungen (3.1) aufgeführt. Die zwei verborgenen Zustandsvektoren des Zellzustands c_{t-1} und Ausgangszustands h_{t-1} aus dem vorherigen Rechenschritt – oder der Initialisierung beim ersten Schritt der Eingangssequenz – sowie der Vektor der Eingangsgrößen zum aktuellen Zeitschritt x_t gehen in die LSTM-Zelle ein. Innerhalb befinden sich neuronartige Berechnungsblöcke, die als Gates bezeichnet werden. Sie sind als schwarze Rechtecke in Abbildung 3.5 dargestellt und entsprechend ihrer Aktivierungsfunktion mit sig oder tanh gekennzeichnet (siehe Gleichungen (3.2)). Die vier Gates enthalten die trainierbaren Parameter der LSTM-Zelle in Form von Gewichten und Offsets, wie anhand der Gewichtsmatrizen W und Offsetvektoren b in den Formeln (3.1) zu erkennen ist.

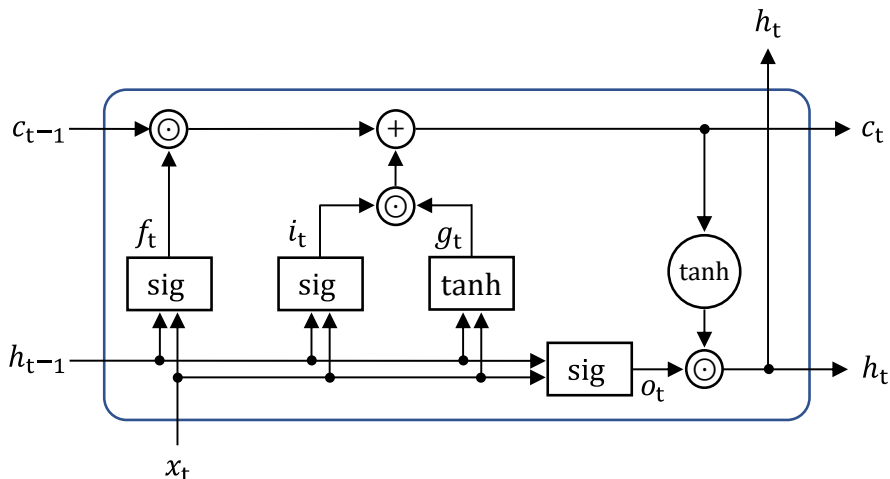


Abbildung 3.5: Informationsfluss und Rechenoperationen in einer LSTM-Zelle (eigene Darstellung). Rechteckige Boxen stehen für Gates mit Sigmoid- (sig) oder Tangens Hyperbolicus (tanh) Aktivierungsfunktion.

Über elementweise Multiplikation (\odot) und Addition werden, wie in Abbildung 3.5 dargestellt, die durch Gates verarbeiteten Zustands- und Eingangsgrößen in der LSTM-Zelle miteinander verrechnet. Den Gates kann jeweils eine spezifische Aufgabe bei der Informationsverarbeitung zugeordnet werden, wovon sich ihre Bezeichnung ableitet [76, 77]. Das „forget“-Gate

entscheidet mit der Berechnung von f_t darüber, welche Teile des vorherigen Zellzustands c_{t-1} weitergeführt werden. Anschließend gewichtet das „input“-Gate mit i_t , wie stark der Zellzustand durch das Ergebnis des „candidate“-Gates g_t auf den Wert c_t aktualisiert wird. Zur Berechnung des Ausgangszustands h_t wird schließlich der aktualisierte Zellzustand c_t mit der tanh-Aktivierungsfunktion verrechnet und mit dem Ergebnis o_t des „output“-Gates gewichtet.

$$\begin{aligned}
 f_t &= \text{sig}(W_{if}x_t + W_{hf}h_{t-1} + b_f) \\
 i_t &= \text{sig}(W_{ii}x_t + W_{hi}h_{t-1} + b_i) \\
 g_t &= \text{tanh}(W_{ig}x_t + W_{hg}h_{t-1} + b_g) \\
 c_t &= f_t \odot c_{t-1} + i_t \odot g_t \\
 o_t &= \text{sig}(W_{io}x_t + W_{ho}h_{t-1} + b_o) \\
 h_t &= o_t \odot \text{tanh}(c_t)
 \end{aligned} \tag{3.1}$$

Die Formeln der zwei Aktivierungsfunktionen in der LSTM-Zelle sind in (3.2) gezeigt. Bei der Sigmoid- (sig) und Tangens Hyperbolicus (tanh) Funktion handelt es sich jeweils um stetige, monoton steigende Funktionen mit einfacher Differenzierbarkeit, was für das Training eines NN mittels Gradientenverfahren von großem Vorteil ist. Die Sigmoid-Funktion besitzt einen Wertebereich von 0 bis 1, Tangens Hyperbolicus einen Wertebereich von -1 bis 1.

$$\begin{aligned}
 \text{sig}(z) &= \frac{1}{1 + e^{-z}} \\
 \text{tanh}(z) &= 1 - \frac{2}{e^{2z} + 1}
 \end{aligned} \tag{3.2}$$

In mehrschichtigen RNN dienen die Ausgangszustände h aller Zellen einer Schicht der nachgelagerten RNN-Schicht als Eingangsgrößen. Aus diesem Grund wird h_t in Abbildung 3.5 auch als Pfeil nach oben dargestellt. Zell- und Ausgangszustände einer Schicht haben die Dimension $(n_{\text{In}}, h_{\text{LSTM}})$, wobei n_{In} die Länge der Eingangssequenz und h_{LSTM} die Zellenanzahl der Schicht (engl. hidden size) ist. Das Ergebnis der letzten Schicht eines RNN, welches z.B. in weiteren NN-Schichten verarbeitet wird, ist der letzte Vektor der Ausgangszustände h_t nach Abschluss der rekursiven Berechnungsschritte. Dieser besitzt die Dimension (h_{LSTM}) , das RNN hat damit die Zeitdimension der Eingangsdaten eliminiert, was als Encodierung bezeichnet wird. Die Zeitreihendaten x , welche in das RNN eingegeben werden, besitzen die Dimension $(n_{\text{In}}, n_{\text{F}})$, abhängig von der Anzahl an Datenkanälen (engl. features) n_{F} . Die Anzahl der trainierbaren Parameter einer LSTM basierten RNN-Schicht ist durch Formel (3.3) in Abhängigkeit von Eingangs- und Schichtgröße gegeben. Die Größe eines RNN hängt

ausdrücklich nicht von der Länge der Eingangssequenz ab, weshalb auch variable Längen in Training oder Inferenz eingesetzt werden können.

$$\text{Anzahl Parameter LSTM-Schicht} = 4 h_{\text{LSTM}}(1 + n_F + h_{\text{LSTM}}) \quad (3.3)$$

3.2.3 Training

Zur Optimierung der Parameter eines RNN im Trainingsprozess wird das gradientenbasierte Verfahren „backpropagation through time“ angewandt, welches eine Erweiterung der „backpropagation“, eingesetzt für das Training klassischer NN, darstellt [76]. Hierbei wird ausgehend von einer Kostenfunktion L_k , welche die Performance des Netzwerks in jeder Iteration (Laufindex k) bewertet, der Gradient über alle Rechenschritte rückwärts durch das NN berechnet – im RNN geschieht das rekurrent über die Zellen und damit rückwärts durch die Zeit der Eingangssequenz. Auf Basis der Gradienten und in Abhängigkeit einer Lernrate werden die Gewichte des Netzwerks zum Abschluss jeder Trainingsiteration angepasst. Es existieren diverse Strategien zur Anpassung der Lernrate im Trainingsprozess, die einen bestmöglichen Kompromiss aus Konvergenzgeschwindigkeit und Optimalität des Ergebnisses anstreben. Bekannte Algorithmen sind Adagrad, RMSprop und Adam [76].

Je Trainingsiteration wird eine definierte Anzahl n_B an Trainingsdaten (engl. samples), bestehend aus Menge der Eingangsgrößen X_k und erwarteten Ergebnisse Y_k^* (GT, engl. ground truth), verarbeitet. Diese sogenannte Batchgröße n_B ist ein sehr wichtiger Trainingsparameter, weil die Menge an Beispieldaten, die das NN erfährt, bevor Kostenfunktion und Gradient berechnet sowie die Parameter adaptiert werden, einen großen Einfluss auf das Konvergenzverhalten der Optimierung hat. Kleine n_B können eine unstetige und langsame Konvergenz verursachen, während zu hohe n_B zu Überanpassung (engl.: overfitting) und numerischen Instabilitäten führen können [78].

In Formel (3.4) ist der allgemeine Aufbau der Kostenfunktion L_k gezeigt. Sie besteht immer aus einem Term E , welcher den Fehler zwischen den Ausgaben des NN Y_k und der GT Y_k^* quantifiziert, und kann außerdem einen bzgl. der Größe der Gewichtsparameter regularisierend wirkenden Term R enthalten. Mit letzterem wird z.B. ein Overfitting auf die Trainingsdaten vermieden und damit die Fähigkeit des NN zur Generalisierung auf ungesehene Daten während der Inferenz verbessert. Die gängigste Funktion zur Berechnung des Fehlers E im Training von Regressionsmodellen ist das in (3.4) dargestellte mittlere Fehlerquadrat (MSE, engl.: mean squared error) [76].

$$L_k = E(Y_k, Y_k^*) + R(W_k, b_k)$$
$$\text{RMSE}(Y_k, Y_k^*) = \frac{1}{|Y_k|} \sum_{y \in Y_k} (y - y^*)^2 \quad (3.4)$$

In den Anwendungen der Trajektorienprädiktion wird typischerweise eine aus mehreren Datenpunkten bestehende Trajektorie über das zukünftige Verhalten berechnet. Neben dem MSE über alle Datenpunkte der Trajektorien werden in manchen Ansätzen auch der mittlere absolute Fehler (MAE), der Fehlerbetrag am letzten Prädiktionspunkt (FDE, engl. final displacement error) oder die Wurzel des MSE (RMSE) als Metriken angewendet [54]. Zur Optimierung multimodaler Prädiktionsmodelle kann außerdem die Kreuzentropie als Kostenfunktion eingesetzt werden.

Ein Overfitting des NN auf die Trainingsdaten kann nicht nur durch eine Bestrafung der Parameter in der Kostenfunktion, sondern auch durch sogenannte „Dropout“-Regularisierung verhindert werden. Für diese werden in jeder Auswertung des NN randomisierte Gewichte deaktiviert, d.h. zu null gesetzt. Dies geschieht mit einer definierten Wahrscheinlichkeit und verhindert, dass das NN zu stark von bestimmten Bereichen seiner selbst abhängig wird, was oft mit Overfitting einhergeht. Für RNN ist die Nutzung der Dropout-Regularisierung unüblich; wenn sie angewendet werden, dürfen während einer Trainingsepoche nur die selben Gewichte abgeschaltet werden [76]. Eine Trainingsepoche ist abgeschlossen, wenn das NN alle Trainingsdaten einmal verarbeitet hat. Die Anzahl der dafür notwendigen Iterationen ist demnach von n_B abhängig. Bis das Training konvergiert ist typischerweise eine zwei- bis dreistellige Anzahl n_E von Epochen notwendig.

Ob Maßnahmen gegen Overfitting erfolgreich sind, wird spätestens beim Test des NN deutlich, für den ein Testdatensatz vor dem Training aus den gesamten zur Verfügung stehenden Daten entnommen wird. Erreicht das NN in der Inferenz auf den unbekanntem Testdaten eine deutlich schlechtere Performance als im Training, dann liegt Overfitting nahe. Damit die Testergebnisse nicht durch Eigenschaften der Daten selbst verfälscht werden (z.B. ein erhöhter Anteil besonders schwieriger Samples in den Testdaten), erfolgt die Ziehung von Testdaten randomisiert. Die für das Training verbleibenden Daten werden zur Vermeidung von Overfitting nochmals randomisiert in Trainings- und Validierungsdaten aufgeteilt. Letztere gehen nicht in die Gradientenberechnung ein. Stattdessen wird die Fehlerfunktion zum

Abschluss einer Epoche auf den Validierungsdaten ausgewertet, um die Konvergenz des Trainings zu überprüfen.

Zufallsmechanismen werden auch während des Trainings von NN eingesetzt, um Konvergenzverhalten und Optimalität der Ergebnisse zu verbessern. Übliche Maßnahmen sind die Initialisierung der Parameter des NN mittels Zufallszahlen und die erneute randomisierte Zuordnung der Trainingssamples zu den Batches zwischen Epochen (engl. shuffling). Aufgrund der Zufallsmechanismen ist es wichtig, mehrere Trainings eines NN-Modells durchzuführen, bevor Schlussfolgerungen gezogen werden. Für die finale Bewertung der Modellgüte anhand von Testdaten empfiehlt sich außerdem die Methode der Kreuzvalidierung. Dabei werden die Aufteilung in Test- und Trainingsdaten, das Modelltraining und der Modelltest so häufig wiederholt, dass mit einer gewissen statistischen Sicherheit mindestens einmal auf jedes Sample des Datensatzes getestet wurde. Als Gesamtergebnis kann dann der Mittelwert aller Testergebnisse ausgewertet werden.

NN stehen für ihre schlechte Interpretierbarkeit in der Kritik. Aufgrund der Vielzahl der Modellparameter und Verknüpfungen innerhalb des NN kann die Wirkung einzelner Eingänge auf das Verhalten des Modells im Ausgang nicht direkt nachvollzogen werden. NN werden deshalb als sogenannte Black-Box Modelle bezeichnet. Ein wichtiges Hilfsmittel zur Untersuchung der Bedeutung einzelner Modellbestandteile oder Eingangsgrößen sind deshalb Ablationsstudien (z.B. in [49]). Das sind Modelltrainings, für die Komponenten des NN-Modells gezielt weggelassen oder hinzugefügt werden, um deren Einfluss auf das Ergebnis zu beobachten. In Abschnitt 8.4 dieser Arbeit wird eine Ablationsstudie zur Analyse der Bedeutung spezieller Eingangsgrößen für die laterale Trajektorienprädiktion durchgeführt.

4 Versuchsmotorrad

Es wird ein Versuchsmotorrad mit Messtechnik aufgerüstet, sodass in Ergänzung zu den gängigen Fahrdynamiksignalen (Drehraten, Beschleunigungen) auch Zustandsgrößen der Lenkung und die querdynamischen Fahrereingaben des Lenkmoments und der lateralen Oberkörperposition des Fahrers gemessen werden. In definierten Fahrversuchen wird damit das querdynamische Übertragungsverhalten unter verschiedenen Fahrereingaben untersucht (Kapitel 5). Außerdem wird das Motorrad zur Erhebung realen Fahrerhaltens in der in Kapitel 6 beschriebenen Datenerhebung eingesetzt.

Grundlegende Fahrzeugdaten und die Standard-Messsignale des Motorrads werden in Abschnitt 4.1 eingeführt. Abschnitt 4.2 behandelt die Messtechnik am Lenksystem und bespricht insbesondere das Lenkmoment, für welches die Entwicklung und Applikation prototypischer Messtechnik notwendig war. Abschließend wird die Charakteristik des Lenkmomentsignals anhand der in dieser Arbeit gesammelten Erfahrungen beschrieben. Zu Beginn des Abschnitts 4.3 werden unterschiedliche Ansätze zur Erfassung der Fahrerbewegung diskutiert. Anschließend sind Realisierung und Performance eines kamerabasierten Messsystems zur Oberkörperpositionserfassung mit optischen Markern beschrieben. Dieses System wird in Abschnitt 4.4 auch für die Ermittlung des Kopfdrehwinkels eingesetzt.

Ziel des Versuchsmotorrads ist eine möglichst allumfassende Messung der querdynamischen Fahrereingaben ohne eine Beeinträchtigung des Fahrers oder Motorrads. Zusätzliche Messsysteme dürfen den Fahrer nicht ablenken oder behindern und das Fahrverhalten des Motorrads sollte sich nicht merklich vom Serienzustand unterscheiden. Ebenso dürfen keine zulassungsrelevanten Eigenschaften, wie z.B. die Festigkeit des Rahmens, beeinträchtigt werden, damit die Betriebserlaubnis für die Durchführung von Testfahrten im öffentlichen Raum erhalten bleibt. Für die prototypische Umsetzung der beiden Messsysteme in den Abschnitten 4.2 und 4.3 bestehen keine Anforderungen an Skalierbarkeit, Haltbarkeit oder Design. Wichtig ist stattdessen eine gute Realisierbarkeit aufgrund limitierter Zeit für den Aufbau des Versuchsmotorrads.

4.1 Basismotorrad

Als Versuchsmotorrad steht eine KTM 1290 Super Adventure S aus dem Baujahr 2018 zur Verfügung. Als Motorrad der Reiseenduro/Adventure-Klasse bietet es sowohl hohen Reisekomfort – ausgeprägt in hoher Zuladung, Sitzkomfort, Windschutz, guten Fahrleistungen

4.1 Basismotorrad

(Beschleunigung, Bremsen, Höchstgeschwindigkeit) und zahlreichen Assistenzsystemen – als auch gewisse Offroad-Fähigkeiten durch lange Federwege und entsprechende Raddimensionen. Dieser Anforderungsspagat führt üblicherweise zu Motorrädern von hoher Masse, die dementsprechend mit leistungs- und drehmomentstarken Motoren ausgestattet sind. Die Eckdaten und im späteren Verlauf benötigte Geometrieparameter des Motorrads sind in Tabelle 4.1 aufgeführt. Für die Verwendung als Versuchsfahrzeug ist insbesondere die hohe Zuladung bzw. das darauf ausgelegte Fahrwerk von Vorteil, weil das Zusatzgewicht der Messtechnik das Fahrverhalten somit nur geringfügig ändert. In Abbildung 4.4b im Abschnitt 4.3.2 ist das Versuchsmotorrad in der Seitenansicht abgebildet.

Parameter	Wert
Masse (exkl. Fahrer, inkl. Messtechnik, Tank leer)	251 kg
Zulässiges Gesamtgewicht	460 kg
Nennleistung, maximales Drehmoment	118 kW, 140 Nm
Reifendimensionen vorne / hinten	120/70 ZR 19 / 170/60 ZR 17
Nachlaufwinkel	26°
Schwerpunkthöhe über Grund (inkl. 86 kg Fahrer, aufrechtes Motorrad)	0,74 m
Laufflächenradius des Reifens vorne / hinten	60 mm / 85 mm

Tabelle 4.1: Wichtige Eckdaten des Versuchsmotorrads KTM 1290 Super Adventure, Baujahr 2018.

Das Motorrad ist mit einem Bosch MSC (Motorcycle Stability Control) System ausgestattet, welches eine schräglagenabhängige Regelung der Bremskraft und Traktionskontrolle realisiert. Das MSC schätzt die aktuellen Fahrzustände Längsgeschwindigkeit, Roll- und Nickwinkel auf Basis der Radgeschwindigkeiten und einer IMU (Inertial Measurement Unit), welche Beschleunigungen in drei und Drehraten um zwei Raumachsen misst [79]. Dank der vorhandenen Schätzer muss keine extra Sensorik oder Algorithmik für die genannten Zustände hinzugefügt werden.

Neben den Fahrdynamikgrößen werden weitere auf dem Fahrzeug-Bus verfügbare Signale gemessen, u.a. Bremsdrücke, Gasgriffstellung und Fahrstufe. Weiterhin wird mit dem „u-blox ZED-F9R“ ein RTK (Real Time Kinematic) und IMU gestütztes GNSS (Globales Navigations-satellitensystem) verbaut, um die absolute Position des Motorrads mit hoher Genauigkeit zu messen.

4.2 Messgrößen im Lenksystem

Bis auf Ausnahmen im Rennsport werden bei Motorrädern keine Zustandsgrößen des Lenksystems gemessen. Es wird deshalb zusätzliche Sensorik zum Erfassen von Lenkwinkel, -rate und -moment installiert.

Der Lenkwinkel wird über ein lineares Potentiometer gemessen, welches parallel zum Lenkungsdämpfer des Versuchsmotorrads an Gabel und Rahmen befestigt ist. Über eine identifizierte Kennlinie wird die Wegstrecke in einen Lenkwinkel umgerechnet. Auf der Gabel wird außerdem eine zusätzliche IMU so montiert, dass eine Sensorachse parallel zur Lenkachse liegt und somit die Lenkrate erfasst wird.

Für die Messung des Lenkmoments an Motorrädern sind verschiedene Methoden aus der Literatur bekannt. Eine Möglichkeit liegt in der Applikation von Dehnmessstreifen (DMS) an Bauteilen des Lenksystems, welche das Lenkmoment übertragen, z.B. an der Lenkstange [18, 74, 80]. In einer früheren Forschungsaktivität bei Bosch wurden der Kraftübertragungspfad des Lenkmoments aufgetrennt und zwei unidirektionale Kraftsensoren in die Lenkerböcke (Verbindung zwischen Lenkstange und Gabelbrücke) eingesetzt [81]; mit diesem Umbau an kraftführenden Teilen des Lenksystems erlischt jedoch die Betriebserlaubnis. Gleiches gilt für den Einsatz einer Drehmomentmesswelle, bei der zusätzlich eine Verschlechterung des Lenkgefühls berichtet wird, weil Spiel und erhöhte Elastizität im Lenksystem auftreten (Steifigkeit des Lenksystems von 5 Nm/° in [64]). Ein weiteres Messprinzip ist der magnetoresistive Drehmomentsensor, welcher von Yamaha zur Lenkmomentmessung im Motorsport eingesetzt wird [82]. Dieser nutzt die unter Torsionsspannung variierenden magnetischen Eigenschaften einer Messwelle aus, um das Lenkmoment zu bestimmen, und ist deshalb steifer als eine Drehmomentmesswelle. Eine besondere, weil außerhalb des Motorrads platzierte, Messmethode wurde von Nugent et al. [83] eingesetzt. Mit Hilfe der Elektromyographie wird die Aktivität mehrerer Muskeln in Arm, Schulter und Rücken eines Probanden gemessen. Damit kann auf seine Lenkaktivität geschlossen werden, nicht jedoch auf absolute Werte des Lenkmoments.

Alle Methoden zur Lenkmomentmessung, die den Kraftübertragungspfad auftrennen, um das Lenkmoment über ein Sensorelement zu führen, werden für das Versuchsmotorrad ausgeschlossen, weil dieses noch im öffentlichen Straßenverkehr bewegt werden soll. Aus diesem Grund werden DMS auf der Lenkstange angebracht, an der ausreichend Bauraum vorhanden ist. Das Lenksystem wird damit weder mechanisch noch geometrisch verändert und das Lenkgefühl bleibt unbeeinflusst.

4.2 Messgrößen im Lenksystem

Mittels geschickter Auswahl und Positionierung der DMS an der Lenkstange wird eine hohe Messgenauigkeit angestrebt. DMS sensieren die Dehnung einer Komponente an der Stelle ihrer Anbringung über die Veränderung des elektrischen Widerstands eines Messgitters (wenige Millimeter Kantenlänge). Durch die Verschaltung eines oder mehrerer Messgitter in einer Wheatstoneschen Brückenschaltung wird die Widerstandsänderung in eine messbare Differenzspannung übersetzt. Um eine möglichst hohe Differenzspannung zu sensieren, wird eine hohe Dehnung je eingebrachter Kraft angestrebt. Die Dehnung einer Komponente wird durch das Elastizitätsmodul des Werkstoffs, dem Flächenträgheitsmoment aus der Geometrie und den wirkenden Spannungen unter Kraftereinwirkung beeinflusst. Das mit 70 GPa vergleichsweise niedrige Elastizitätsmodul von Aluminium ist der Messgenauigkeit förderlich. Das Flächenträgheitsmoment ist dank eines nahezu konstanten Querschnitts über die gesamte Länge der runden Lenkstange gleich. Fahrereingaben an den Griffen des Lenkers äußern sich in Biegemomenten in der Lenkstange, die zu deren Einspannung an den Lenkerböcken hin zunehmen. Dort treten entsprechend die höchsten Spannungen auf, weshalb die DMS so nah wie möglich an der Einspannung platziert werden. In Abbildung 4.1 ist der spiegelsymmetrische Lenker in zwei Ansichten skizziert, links in Richtung der X_S -Achse und rechts entgegen der Z_S -Achse des Lenk-KS gesehen. Die Lenkerböcke sind als ausgefüllte schwarze Rechtecke und die DMS als rote und blaue Rechtecke dargestellt.




Abbildung 4.1: Skizze der spiegelsymmetrischen Lenkstange samt Dehnmessstreifen, links in Fahrtrichtung gesehen und rechts in der Draufsicht.

Wie in Abbildung 4.1 symbolisiert, werden DMS sowohl für die Messung des Lenkmoments M_z (blau), verursacht aus Fahrereingaben $F_{H,x}$ in X_S -Richtung, als auch für die Messung des Abstützmoments M_x (rot), verursacht aus Fahrereingaben $F_{H,z}$ in Z_S -Richtung, eingesetzt. Auf der linken und rechten Lenkerhälfte sind jeweils zwei DMS-Vollbrücken, eine für M_z und eine für M_x der jeweiligen Lenkerseite, angebracht. Unter den verschiedenen Möglichkeiten zur Brückenschaltung von DMS besitzt die Vollbrücke die höchste Sensitivität, d.h. sie ermöglicht

die höchste Messgenauigkeit. Sie besteht aus vier DMS-Messgittern, die paarweise beidseitig der Biegeachse angeordnet sind, sodass zwei Messgitter unter dem Biegemoment gestaucht und zwei gedehnt werden [84]. Außerdem bietet sie eine vollständige Kompensation mechanischer Störungen (z.B. Normalkräfte) und von Temperatureinflüssen.

Mithilfe der Geometrieparameter der Lenkstange an der Applikationsstelle der DMS, der Hebelarme l_H und l_{DMS} , der Verstärkungsfaktoren von Messgitter und Brückenschaltung und der Anforderung des maximalen Messbereichs erfolgt die Auslegung des DMS-Messsystems anhand analytischer Formeln. Sie kann in Anhang A.2 nachverfolgt werden. Als maximal zu messendes Lenkmoment M_z werden 120 Nm festgelegt, was 20 % über der Maximalangabe aus dem Stand der Forschung in Abschnitt 2.1 liegt. Dieser Puffer wird zum einen aufgrund des vergleichsweise breiten Lenkers des Adventure-Motorrads gewählt. Zum anderen wird eine gleichmäßige Aufteilung, d.h. maximal 60 Nm je Lenkerhälfte, angenommen. Für M_x wird die gleiche Lastannahme getroffen. Die analytische Auslegung bestimmt den Verstärkungsfaktor der analogen Messverstärker, welche die Differenzspannung der DMS-Vollbrücken in eine Ausgangsspannung von 0 bis 5 V überführen. Mittels diesem und den Kalibrierwerten der Messverstärker wird abgeschätzt, dass der Fehler der Messkette unter 0,1 Nm liegt.

Weil die analytische Umrechnung von Momenten an der Lenkstange in Dehnungen vereinfachenden Annahmen unterliegt (z.B. ist der Einfluss der Klemmung in den Lenkerböcken auf die Spannungsverteilung in der Lenkstange nicht abgebildet), erfolgt eine Kalibrierung der mit DMS applizierten Lenkstange auf dem Prüfstand von Wahl et al. [81]. Er beinhaltet eine starr montierte originale Gabelbrücke mit Lenkerböcken des Versuchsmotorrads, in denen die Lenkstange mit definiertem Anzugsmoment montiert wird. Beide Seiten der Lenkstange können einzeln oder kombiniert mit Kräften in X_S - und Z_S -Richtung belastet werden, indem Gewichte über (teilweise umgelenkte) Seile an die Lenkerenden angehängt werden. In den jeweils statischen Belastungszuständen werden die Spannungen an den Ausgängen der Messverstärker aller vier DMS-Vollbrücken notiert. Je Lenkerhälfte und Krafrichtung werden vier Lastzustände gemessen, je zwei in negative und positive Richtung. Maximal werden ± 40 Nm je Lenkerhälfte und damit zwei Drittel des maximalen Messbereichs abgeprüft. Einige Messpunkte werden wiederholt, um Hysterese-Effekte des Aluminiumwerkstoffs zu kompensieren. Ergebnis der Kalibrierung sind vier linear gefittete Kennlinien zur Umrechnung der Ausgangsspannungen an den vier DMS-Vollbrücken in wirkende Momente ($M_{z,l}$, $M_{z,r}$, $M_{x,l}$, $M_{x,r}$). Es ergeben sich außerordentlich lineare Spannungs-Momentkennlinien, die R^2 -Metrik des Fittings ist jeweils größer als 0,999.

Im Laufe der Kalibrierung wird auch die gleichzeitige Belastung in beide Krafrichtungen gemessen. Diese bestätigt, dass es keine gegenseitige Beeinflussung in der Messung von M_z

und M_x gibt. Ebenfalls wird festgestellt, dass keine Spannungen von einer auf die andere Lenkerhälfte übersprechen. Ein zweiter Kalibrierungsdurchlauf ergibt, dass eine erneute Montage der Lenkstange in den Lenkerböcken einen Offset im lastfreien Zustand der DMS verursachen kann, die Gradienten der Spannungs-Moment-Kennlinien aber gleichbleiben. Weil der Lenker für die Montage am Versuchsmotorrad zwangsläufig neu eingespannt werden muss und die Stärke der Klemmung zudem temperaturabhängigen Schwankungen unterliegt, muss der Offset im lastfreien Zustand für jede Messung individuell kompensiert werden. Dies wird in einer entsprechenden Routine in der Messdatennachbereitung automatisiert, welche die lastfreien Zustände zu Beginn und Ende einer Messung berücksichtigt.

Anhand einer Beispielmessung soll die Charakteristik des Lenkmomentsignals verdeutlicht werden. Abbildung 4.2 zeigt die Fahrt durch eine 180°-Rechtskurve mit etwa 50 km/h. Das Rohsignal des Lenkmoments M_z ist als magentafarbene Linie dargestellt. Nach der phasenfreien Filterung mit einem Tiefpass mit 5 Hz Eckfrequenz – der obersten Grenzfrequenz für aktive Lenkeingaben des Motorradfahrers (siehe Abschnitt 2.1) – ergibt sich der schwarze Signalverlauf $M_{z,fil}$. Über den gesamten Messverlauf fallen hochfrequente Störungen beim Vergleich von M_z und $M_{z,fil}$ auf. Sie werden durch Fahrbahnanregungen am Vorderrad und Motorvibrationen verursacht. Erstere wirken sich unter Rollwinkel, also besonders im Bereich der stationären Kurvenfahrt zwischen 2 und 6 s, noch stärker auf die Lenkung aus. Im Boxplot rechts in Abbildung 4.2 ist die Differenz von M_z und $M_{z,fil}$ statistisch gezeigt. Die Whisker grenzen 5 % und 95 % Quantil als Ausreißer ab, d.h. 10 % aller Messpunkte sind stärker als 2,4 Nm gestört.




Abbildung 4.2: Signalverlauf von ungefiltertem und 5 Hz Tiefpass gefiltertem Lenkmomentsignal in einer 180°-Rechtskurve.

Die im Verlauf von $M_{z,fil}$ in Abbildung 4.2, insbesondere während der stationären Kurvenfahrt, verbleibenden Schwankungen sind sowohl der Stabilisierung des Rollwinkels als auch der Bahnführung des Motorrads (Spurkorrekturen) durch den Fahrer geschuldet.

Um einen Einblick in die Größenordnungen des gefilterten Lenkmoments in verschiedenen Fahrsituationen zu geben, sind in Abbildung 4.3 Erfahrungswerte aus diversen Messungen mit dem Versuchsmotorrad dargestellt. Sie sind spezifisch für Motorrad und Reifen und deshalb nur als Anhaltswerte zu verstehen. In Geradeausfahrt sind die Lenkmomente zur Stabilisierung und Bahnführung erwartungsgemäß klein. Aufgrund der erläuterten Störungseinflüsse liegt dann jedoch – besonders bei schlechterer Fahrbahnbeschaffenheit – ein herausforderndes Signal-Rauschverhältnis vor. Das für konstante Kurvenfahrt notwendige Lenkmoment hängt von Fahrzustand (Geschwindigkeit, Rollwinkel) und Fahrstil ab und kann beide Vorzeichen (nach kurveninnen oder -außen) oder auch 0 Nm annehmen. Beim Einleiten eines dynamischen Ausweichmanövers bei Geschwindigkeiten von 30 bis 100 km/h wurden Lenkmomentamplituden zwischen 30 und 50 Nm beobachtet. Maximalwerte von etwa 100 Nm haben Fahrer bei sportlich aggressiver Fahrt auf einem Handlingkurs erreicht. Der maximale Messbereich des DMS-Messsystems wurde somit ausreichend groß gewählt.

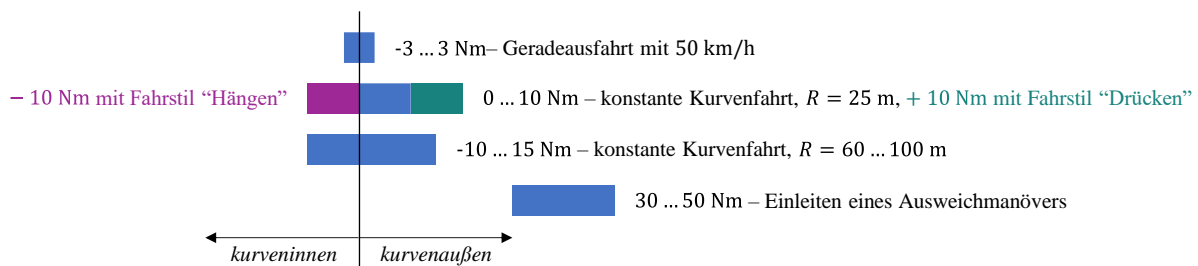


Abbildung 4.3: Größenordnungen des gefilterten Lenkmoments in diversen Fahrsituationen mit Angabe der Richtung, in die es aufgebracht wird.

4.3 Fahrerpositionserfassung

Wie in Abschnitt 2.1 erläutert wurde, bewegen sich Motorradfahrer in Kurvenfahrt relativ zum Fahrzeug. Dabei beeinflusst die laterale Verschiebung ihres Körperschwerpunkts die Querdynamik (siehe Abschnitt 3.1). Eine Veränderung der Höhen- und Längsposition des Fahrerschwerepunkts wirkt sich hingegen vorwiegend auf die Längsdynamik aus. Dem Fokus der Dissertation auf die Kurvenfahrt entsprechend, wird die Messung der lateralen Fahrerposition angestrebt. Folgend werden diverse prototypische Messmethoden diskutiert, die aus den in Abschnitt 2.1 beschriebenen Untersuchungen zum Fahrerverhalten bekannt sind.

4.3.1 Messmethoden

Evertse [30] nutzt eine direkte Messung des Fahrerrollmoments zur Bestimmung der Fahrerbewegung, indem wechselwirkende Kräfte zwischen Fahrer und Fahrzeug sensiert, mit einem virtuellen Hebelarm bzgl. der Rollachse multipliziert und aufsummiert werden. Dies

birgt einen hohen mechanischen Integrationsaufwand, weil die physischen Schnittstellen zwischen Fahrer und Motorrad vielfältig und komplex sind. Der Fahrer ist hauptsächlich mit Lenker, Fußrasten und Sitz in Kontakt. Es ist jedoch nicht auszuschließen, dass noch weitere Kontaktpunkte bestehen, z.B. zwischen Rahmen oder Tank und den Beinen des Fahrers. Komplexe Sensorelemente sind notwendig, weil an Lenker, Fußrasten und Sitz Kräfte in alle Raumrichtungen eingebracht werden können. Eine zusätzliche Herausforderung birgt die Interpretation des Fahrerrollmoments, denn dieses ist in Kurvenfahrt auch für einen komplett passiven Fahrer (keine Positionsveränderung) nicht null, weil dieser die dynamischen Kräfte aufgrund seiner Massenträgheit am Motorrad abstützen muss. Aufgrund des hohen Aufwands und der Komplexität wird diese Messmethode nicht verfolgt.

Bocciolone et al. [43] befestigen mehrere Seile am Rücken des Fahrers, deren Längen von Potentiometern gemessen werden. Über kinematische Gleichungen werden daraus der laterale Versatz und die Neigung des Fahreroberkörpers errechnet. Die mechanische Anbindung des Fahrers an ein Messsystem ist hinsichtlich der Veränderung des Fahrgefühls kritisch zu hinterfragen und kommt aufgrund der mechanischen Komplexität und aus Sicherheitsaspekten für Fahrversuche im öffentlichen Straßenverkehr nicht in Frage.

Ein kombinierter Ansatz, bestehend aus Kraftmessung in Sitz und Lenker und Dynamikmessung mittels IMU am Fahrer, wird von Zhang [85] für ein Fahrrad realisiert. Basierend auf Dynamikmodellen von Zweirad und Fahrer schätzt ein Kalman-Filter aus den Messgrößen die Oberkörperneigung. Ein lateraler Versatz des Oberkörpers wird nicht berücksichtigt, weil dieser für Fahrräder nicht üblich ist. Die Validierung des Schätzers ist aufwendig, weil ein zweites, Kamera basiertes Messsystem eingesetzt wird.

In Fahrversuchen von Scherer, Pleß & Winner [33] und Cheli et al. [42] wird ein optisches Messsystem für die Bestimmung der Oberkörperposition auf dem Motorrad verwendet. Beide nutzen eine Kamera, die den Fahrer von hinten filmt, und optische Marker, die auf dem Rücken des Fahrers angebracht sind. Marker bieten charakteristische Reflexionen oder Muster und erleichtern damit die algorithmische Auswertung des Kamerabilds. Carputo et al. [86] nutzen die gleiche Rückansicht des Fahrers, werten das Kamerabild jedoch mit einem NN aus, um auf Marker verzichten zu können. Sie verwenden dazu ein OpenPose genanntes, bestehendes NN-Modell aus der Forschung zum Tracking menschlicher Bewegungen. Dieses muss jedoch mittels Training auf die Motorradanwendung spezialisiert werden, um ausreichende Güte in der Oberkörperpositionsbestimmung zu erreichen. Für die Erzeugung von Trainingsdaten ist neben zahlreichen Fahrversuchen (Zeitaufwand) auch ein Referenz-Messsystem notwendig. Optische Messsysteme zur Fahrerpositionserfassung auf dem Motorrad, die Radar- oder Lidar-Sensorik verwenden, sind aus dem Stand der Forschung nicht bekannt.

4.3.2 Kamerabasierte Oberkörperpositionserfassung

Aus Gründen der hohen Verfügbarkeit, der einfachen mechanischen Integration und einer nicht vorhandenen Ablenkung des Fahrers oder Veränderung des Fahrgefühls wird eine Kamera hinter dem Fahrer angebracht, die seine Position aufzeichnet. Vorteil der Rückansicht ist, dass Arm- oder Lenkerbewegung die Oberkörperpose nicht verdecken können. Eine Erkennung des Fahrers bei der Fahrt mit Sozius ist jedoch nicht möglich, was für die angestrebten Tests aber irrelevant ist.

In Anlehnung an den Stand der Technik wird die Fahrerposition durch Angabe von Neigungswinkel φ_F und lateralem Versatz y_F des Oberkörpers relativ zum Motorrad beschrieben. Oberkörper, Kopf und Oberarme machen mit 64 % den Großteil des Körpergewichts aus (Mittelwerte Mann und Frau aus [87]) und werden am stärksten bewegt, weshalb sie im Sinne des querdynamischen Einflusses auf die Fahrdynamik am interessantesten sind. Die von der Kamera nicht erfassten Bewegungen von Armen und Beinen sind weniger ausgeprägt und deshalb von nachrangigem Interesse, weil Füße und Hände an den Fußrasten und am Lenker verbleiben. Weiterhin wird die für Straßenverkehr vertretbare Annahme getroffen, dass der Motorradfahrer nicht im Stehen fährt und die Höhenkoordinate des Oberkörpers demnach nicht ausgewertet werden muss.

Zur Bestimmung der Oberkörperposition aus dem Kamerabild werden optische Marker eingesetzt, nachdem die Verwendung von NN zu aufwendig ist und einfache Methoden der Bildverarbeitung (z.B. die „Canny Edge Detection“) zu geringe Performance erreichen [88].

Die Notwendigkeit der Anbringung von Markern am Rücken des Motorradfahrers ist im Hinblick auf eine Fahrstudie mit mehreren Probanden nachteilig, weil aufwendig und fehleranfällig. Die optischen Marker werden deshalb einmalig in definierter Ausrichtung auf einer Protektorweste angebracht, welche die Fahrer über ihre persönliche Schutzausrüstung überziehen. Durch Gummizüge wird ein enganliegender Sitz der Weste gewährleistet, damit sie unter den Fahrerbewegungen während der Fahrt nicht verrutscht.

Die Protektorweste mit Markern ist in Abbildung 4.4a in einem beispielhaften Bildausschnitt der Kamera aus einer Messfahrt zu sehen. Es sind vier Marker entlang der vertikalen Mittellinie der Protektorweste angebracht, um die Rückenlinie (grüne Linie in Abbildung 4.4a) robust zu detektieren, denn mindestens zwei Marker müssen dazu zeitgleich erkannt werden. Ein möglichst großer Abstand der Marker hilft den Fehler in der Berechnung von φ_F gering zu halten. Um eine Krümmung des Rückens zuzulassen, besteht der Protektor aus mehreren horizontalen Elementen, die sich vertikal zueinander verschieben können. Es werden deshalb zwei zusätzliche Marker auf ein starres Element der Weste aufgebracht, damit ein bekannter

4.3 Fahrerpositionserfassung

und fester Abstand als Referenz vorhanden ist. Als Stützpunkt für die Angabe des lateralen Versatzes des Oberkörpers wird der unterste Marker auf der Rückenlinie definiert. Er besitzt die Identifikationsnummer (ID) 5, weshalb der laterale Versatz in Abbildung 4.4a als $y_{F,M5}$ bezeichnet wird. Marker 5 liegt nahe des Drehpunkts, wenn Fahrer ausschließlich den Oberkörper neigen und sich nicht auf dem Sitz umsetzen. Der exakte Drehpunkt unterscheidet sich jedoch von Fahrer zu Fahrer und wandert mit zunehmender Oberkörperneigung. Es sind zusätzlich zwei Marker auf dem Tank angebracht, welche die Mittellinie des Motorrads markieren (X_V - Z_V -Ebene). Diese wird als Referenz für die Berechnung von φ_F und $y_{F,M5}$ benötigt und ist in Abbildung 4.4a in blau dargestellt. Die Marker auf dem Tank sind zu Beginn und Ende einer Messung im Sichtfeld der Kamera, wenn der Fahrer nicht auf dem Motorrad sitzt.




Abbildung 4.4: a) Bildausschnitt der Kamera zur Fahrerpositionserfassung. Rückenlinie (grün) und Mittellinie des Motorrads (blau) sind hervorgehoben. Ermittelte Oberkörperlage in φ_F und $y_{F,M5}$ angegeben. b) Seitenansicht des Versuchsmotorrads mit hervorgehobenem Kamera-Sichtfeld.

Für die bestmögliche Erkennung zweidimensionaler Marker sollte die Bildebene der Kamera parallel zu ihnen ausgerichtet sein. Weil der Fahrer auf einem Adventure-Motorrad eine ohnehin sehr aufrechte Sitzposition innehat und am Versuchsmotorrad zudem ein Topcase für die Messtechnik hinter dem Fahrer montiert ist, kann dies einfach realisiert werden. Abbildung 4.4b zeigt das Versuchsmotorrad in der Seitenansicht, wobei die Kameraposition durch das blaue Sichtfeld hervorgehoben ist. Anhand dieser Position wird eine Kamera ausgewählt, dessen Optik einen genügend großen Bildausschnitt ermöglicht. Sie muss außerdem robust gegenüber Umwelteinflüssen wie z.B. Regen oder Vibrationen sein. Die Kamera darf keinen optischen Bildstabilisator besitzen, damit eine eindeutige Zuordnung der Positionen im Bild in allen Frames einer Videoaufnahme gegeben ist. Es wird eine „GoPro Hero 3 Black Edition“

ausgewählt, die mit 720p Auflösung und einer Bildrate von 100 fps aufnimmt. Durch die hohe Bildrate wird sichergestellt, dass die Marker auch bei schnellsten Fahrerbewegungen nicht verschwommen aufgenommen werden.

Es wird das aus der Robotik-Forschung bekannte AprilTag Markersystem eingesetzt, welches an der University of Michigan entwickelt wurde [89, 90]. Für die robuste, präzise und effiziente Erkennung von Position und Orientierung der QR-Code ähnlichen quadratischen Marker ist Open Source Software (BSD-2-Clause-Lizenz) verfügbar. Diese errechnet die dreidimensionale Position und Orientierung aller erkannter Marker relativ zum Kamerasensor in einem Frame; dafür müssen die intrinsischen Kameraparameter bekannt sein, die mittels einer Kalibrierung bestimmt werden. Basierend auf Pilotversuchen wird der Marker-Typ „36h11“ ausgewählt, der den besten Kompromiss aus Erkennungsrate, Rechenzeit und Präzision darstellt. Um die zur Auswertung der Kamerabilder notwendige Rechenzeit weiter zu minimieren, wird ein Algorithmus entwickelt, der einzelne Frames bei niedriger Dynamik der Fahrerbewegung überspringt und stellenweise nur Teilbereiche eines Frames auf Marker absucht [88]. Er fußt auf der Annahme, dass der Fahrer nur eine begrenzte Bewegungsgeschwindigkeit hat.

Aus den extrahierten Positionskordinaten der Marker werden in einem zweiten Algorithmus die Messgrößen φ_F und $y_{F,M5}$ der Fahreroberkörperposition ermittelt. Er ist in Anhang A.3 beschrieben.

4.3.3 Beispielmessung und Messgenauigkeit

Das Verhalten der zwei Messgrößen der Oberkörperpositionserfassung (φ_F und $y_{F,M5}$) ist für eine beispielhafte Kurvenkombination, charakterisiert durch den Verlauf des Rollwinkels in gestrichener blauer Linie, in Abbildung 4.5 gezeigt. Der lateraler Versatz $y_{F,M5}$ ist sowohl als Rohsignal in Form von Datenpunkten als auch nach Filterung mittels 2 Hz Tiefpass als Linie $y_{F,M5,fil}$ dargestellt. Abgesehen von wenigen Ausreißern, in denen der Marker 5 nicht erkannt und seine Position deshalb approximiert wurde, liegt ein glatter Signalverlauf vor. Für den Neigungswinkel φ_F des Fahreroberkörpers wird in Abbildung 4.5 ausschließlich das Rohsignal gezeigt, weil keine signifikanten Ausreißer auftreten. Die erkennbare Rauheit beider Signalverläufe resultiert aus den Motorvibrationen.

Wie an der überwiegenden Vorzeichengleichheit von Fahrzeugrollwinkel φ und $\varphi_{F,fil}$ in Abbildung 4.5 erkennbar ist, lehnt sich der Fahrer in den transienten Richtungsänderungen dieser Kurvenkombination zusätzlich zum Motorrad in die Kurven hinein. Er nutzt demnach den Fahrstil „Hängen“. In der langen Phase stationärer Kurvenfahrt von 4 bis 11 s kehrt er aber

4.3 Fahrerpositionserfassung

wieder in den Fahrstil „Legen“ zurück, denn hier geht φ_F auf null. Der laterale Versatz $y_{F,M5,fil}$ hat geringe Amplituden und einen nahezu vorzeichenverkehrten Verlauf verglichen mit φ_F . Dies spricht dafür, dass der Fahrer seinen Sitzpunkt während der Kurvenkombination nicht aktiv verändert. Die Ausschläge rühren stattdessen daher, dass der Drehpunkt der Oberkörperneigung für diesen Fahrer nicht in Marker 5, sondern darunter liegt.




Abbildung 4.5: Signalverlauf von Neigungswinkel φ_F und lateralem Versatz $y_{F,M5}$ des Fahreroberkörpers für eine Kurvenkombination. $y_{F,M5}$ ist ungefiltert und $y_{F,M5,fil}$ mit 2 Hz Tiefpass gefiltert dargestellt.

Robustheit und Messgenauigkeit der kamerabasierten Fahrerpositionserfassung werden in realer Fahrt geprüft. Dies liefert belastbare Ergebnisse, weil auf dem Versuchsmotorrad Störungen wie z.B. Luftverwirbelungen, Vibrationen aus Straßenanregung und vom Antriebsstrang auftreten, die in einem statischen Test schwierig nachzubilden sind. Zudem treten während der Fahrt wechselnde Lichtverhältnisse auf, welche die Erkennung der Marker beeinträchtigen können.

Für die Bewertung der Robustheit wird die Erkennungsrate aller Marker auf der Protektorweste ausgewertet. Über die Dauer einer Validierungsfahrt erreicht diese den hohen Wert von 99,3 %. Die Marker werden auch bei schnellsten Fahrerbewegungen erkannt, woraus geschlossen wird, dass die gewählte Framerate von 100 fps ausreichend hoch ist. Vereinzelt verpasste Detektionen werden auf schwierige Lichtverhältnisse (insbesondere Schatten und Reflexionen) zurückgeführt.

Zur Bestimmung der Messgenauigkeit wird der bekannte Abstand der zwei horizontalen Referenzmarker auf der Protektorweste in jedem Frame mit dem vom Auswertalgorithmus berechneten Abstandswert verglichen. Eine Validierungsfahrt ergibt eine Standardabweichung des Abstandsfehlers von nur 0,4 mm. Der maximale Fehler beträgt 10 mm und ist in einer dynamischen Fahrsituation aufgetreten. Wird das gleichzeitige Auftreten einer 10 mm Abweichung an mehreren Markern entlang der Rückenlinie angenommen, mündet dies in einem Fehler von 3° in φ_F . In beiden Messgrößen werden die selbstgesteckten Anforderungen

von weniger als 20 mm und 7° Abweichung, deren Herleitung in [88] erläutert ist, sicher eingehalten. Entscheidender für eine genaue Messung ist der korrekte und feste Sitz der Protektorweste am Rücken des Fahrers.

4.4 Messung der Kopfdrehung

Das für die Fahrerpositionserfassung entwickelte Kamera-Messsystem kann zusätzlich für die Messung der Kopfdrehung eingesetzt werden. Im Sinne der Untersuchung von Fahrerverhalten ist diese Messgröße von Interesse, weil in der Kopfdrehung Informationen zur Blickrichtung und damit Fahrerabsicht vermutet werden.

Die Kopfdrehung wird als Drehwinkel des Helms ψ_H um die Rückenlinie des Fahrers definiert. Für die Erkennung werden drei Marker horizontal verteilt am Helm angebracht. Sie sind in Abbildung 4.4a zu sehen. Damit soll sichergestellt werden, dass immer mindestens ein Marker möglichst parallel zur Kameralinse steht, was wichtig für eine robuste Erkennung ist. In einem Extraschritt des zweiten Auswertalgorithmus werden die orthogonalen Abstände aller erkannten Helmmarker zur Rückenlinie errechnet (siehe Anhang A.3). Für jeden der drei Marker wurde in Referenzmessungen eine Kennlinie ermittelt, anhand derer die Abstände in einen Drehwinkel ψ_H übersetzt werden. Die Ergebnisse bei mehreren erkannten Helmmarkern werden zu einem finalen ψ_H gemittelt.

Abbildung 4.6 zeigt den Signalverlauf der Kopfdrehung in der gleichen Kurvenkombination, die schon in Abbildung 4.5 als Beispiel herangezogen wurde. Es werden die Rohsignale ψ_H als Datenpunkte und das mit 2 Hz Tiefpass gefilterte Signal $\psi_{H,fil}$ als Linie dargestellt. Im Vergleich fallen charakteristische Ausreißer auf, die aufgrund des Umschaltens zwischen verschiedenen Helmmarkern bei der Berechnung des Kopfdrehwinkels mittels linearer Kennlinien entstehen. Zudem treten Zeitlücken wegen fehlender Erkennung der Helmmarker auf. Die Robustheit der Erkennung fällt im Vergleich zur Fahrerpositionserfassung schlechter aus, weil der Helm am weitesten von der Kamera entfernt ist, die Marker bei Kopfdrehung aus der Bildebene heraus verdreht werden und die Lichtverhältnisse am stärksten schwanken. Auffällig sind außerdem große Schwankungen zwischen verschiedenen Fahrern, die auf unterschiedliche Körpergrößen und Helmformen zurückgeführt werden.

Die Kopfdrehung folgt eindeutig dem Kurvenverlauf in Abbildung 4.6, indem $\psi_{H,fil}$ (schwarze Linie) spiegelverkehrt zum Rollwinkel φ (blau gestrichene Linie) verläuft. Es ist sogar ein leichtes Vorseilen von $\psi_{H,fil}$ in den transienten Übergängen erkennbar.




Abbildung 4.6: Signalverlauf des Kopfdrehwinkels (Rohsignal ψ_H und 2 Hz Tiefpass gefiltert $\psi_{H,fil}$) für eine Kurvenkombination.

Das Verhalten der Kopfdrehung von Motorradfahrern wird in Abschnitt 6.4 systematisch für Kurvenfahrten im realen Straßenverkehr untersucht, um die Relevanz dieser neuartigen Messgröße für die Erkennung der Fahrerabsicht bzgl. der vorausliegenden querdynamischen Fahrtrajektorie einzuschätzen.

5 Identifikation des querdynamischen Übertragungsverhaltens

Wie die Ergebnisse des Stands der Forschung zu Fahrereingaben und -verhalten in Querdynamik in Abschnitt 2.1 zeigen, ist das Lenkmoment die primäre, weil im Vergleich zur lateralen Fahrerbewegung vielfach effektivere, querdynamische Fahrereingabe. Trotzdem nutzen Motorradfahrer die sekundäre Eingangsgröße der Oberkörperbewegung und nehmen damit potenziell Einfluss auf das Übertragungsverhalten der Querdynamik. Eine umfangreiche experimentelle Identifikation dieses Übertragungsverhaltens in sowohl quasistationärer als auch transientser Fahrt und unter verschiedenen Fahrereingaben wird durchgeführt, weil sie in der Literatur nicht verfügbar ist. Sie dient dazu, das Potenzial der zwei Fahrereingangsgrößen für eine physikalische Trajektorienprädiktion zu bewerten und gibt zudem erste Einblicke in natürliches Fahrerverhalten.

Dass für Untersuchungen der querdynamisch wirksamen Fahrereingaben weder Simulation noch Fahrsimulator verwendet werden können, ist durch die in Abschnitt 3.1 dargestellten Herausforderungen begründet. Deshalb werden Fahrversuche mit dem in Kapitel 4 beschriebenen Versuchsmotorrad auf einer abgesperrten Teststrecke durchgeführt. Es fahren insgesamt drei verschiedene Testfahrer, von denen jeweils zwei Fahrer die gleichen Versuche absolvieren. Die Fahrerfahrung reicht vom „Gelegenheitsfahrer“ bis zum „erfahrenen Fahrer“, es ist kein „Anfänger“ und kein „Profi“ (z.B. Rennfahrer) unter den Dreien.

Mit quasistationären Kreisfahrten wird in Abschnitt 5.1 das Übertragungsverhalten in stationärer Querdynamik untersucht, wobei insbesondere die Beeinflussung des Lenkmoments durch unterschiedliche Oberkörperpositionen betrachtet wird. Abschnitt 5.2 behandelt das Übertragungs- und Fahrerverhalten in transienten Slalom- und Spurwechselmanövern. Das Timing der Fahrereingaben liefert hierbei wichtige Erkenntnisse für die Bedeutung der Größen für eine physikalische Trajektorienprädiktion. Die Schlussfolgerungen für die weitere Arbeit an der lateralen Trajektorienprädiktion sind in Abschnitt 5.3 erläutert.

5.1 Stationäre Kurvenfahrt

Zur Untersuchung der stationären Kurvenfahrt werden Kreisbahnen mit konstantem Radius gefahren. Durch die schrittweise Variation der Geschwindigkeit werden je Radius verschiedene Rollwinkel eingestellt. Ein ideal stationärer Fahrzustand kann dabei in Fahrversuchen nicht realisiert werden, weil der Motorradfahrer ständige Rollwinkelkorrekturen zur Stabilisierung und Bahnführung vornimmt. Deshalb wird zunächst das Vorgehen zur Auswertung der

5.1 Stationäre Kurvenfahrt

Kreisfahrten erläutert. In Abbildung 5.1a ist die Rollrate $\dot{\phi}_{\text{fil}}$ (5 Hz Tiefpass gefiltert) in Form grauer Datenpunkte über dem Rollwinkel ϕ für die Fahrt im Uhrzeigersinn auf einer Kreisbahn mit 25 m Radius dargestellt; es treten Korrekturen in $\dot{\phi}_{\text{fil}}$ mit einer Amplitude von bis zu 10 °/s auf. Zur Auswertung der Kreisfahrten wird deshalb ein quasistationäres Kriterium (Index QS) definiert, demzufolge nur Abschnitte der Messung berücksichtigt werden, in denen für mindestens zwei Sekunden $|\dot{\phi}_{\text{fil}}| < 5 \text{ °/s}$ und $|a_{x,\text{fil}}| < 1,2 \text{ m/s}^2$ eingehalten wird. Die so gefilterten Datenpunkte $\dot{\phi}_{\text{fil,QS}}$ sind in Abbildung 5.1a grün dargestellt.

In Abbildung 5.1b ist das Fahrerlenkmoment $M_{z,\text{fil,QS}}$ während der quasistationären Abschnitte des gleichen Manövers in grün gezeigt (5 Hz Tiefpass). Es streut aufgrund der Rollwinkelkorrekturen und aufgrund einer Fahrbahnneigung der Teststrecke in einem Band von 5 bis 7 Nm Breite. Um den Neigungseinfluss zu entfernen, werden die Werte $M_{z,\text{fil,QS}}$ über eine vollständige Runde auf der Kreisbahn gemittelt (Index FC). Es ergeben sich die in Abbildung 5.1a & b schwarz dargestellten Datenpunkte $\overline{\dot{\phi}}_{z,\text{fil,FC}}$ und $\overline{M}_{z,\text{fil,FC}}$.

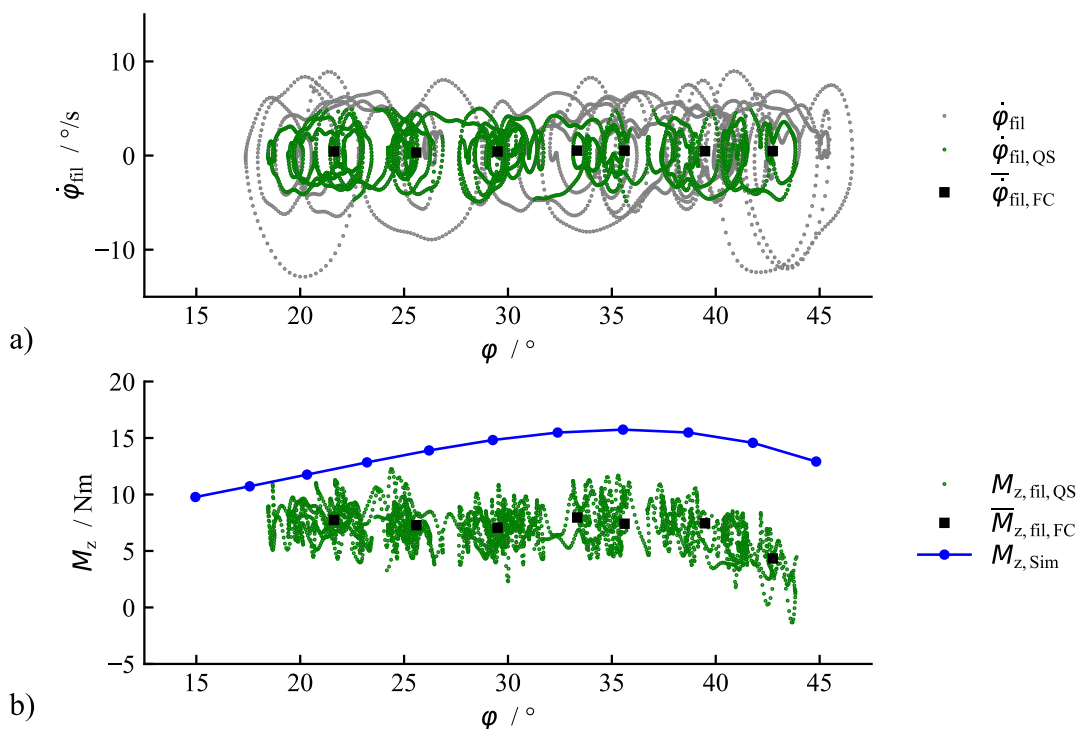


Abbildung 5.1: Rollrate (a) und Lenkmoment (b) in Kreisfahrt auf 25 m Radius. Mit 5 Hz Tiefpass (fil) und quasistationärem Kriterium (QS) gefilterte sowie über vollständige Kreise (FC) gemittelte Daten. Lenkmomente aus der Mehrkörpersimulation (Sim) zeigen die Abweichung der Simulation.

Die Nachsimulation der gleichen Kreisfahrt mit 25 m Radius an mehreren stationären Betriebspunkten in der Mehrkörpersimulation ergibt die in Abbildung 5.1b blau dargestellten Lenkmomente $M_{z,\text{Sim}}$. Der deutliche Abstand und abweichende Gradient im Vergleich zu den gemessenen Momenten wird durch die unzureichende Modellierung des Reifens (Magic

Formula Reifenmodell) verursacht und bekräftigt die Durchführung von Fahrversuchen für Untersuchungen im Zusammenhang mit dem Lenkmoment.

Um zu beobachten, wie sich das Verhalten des Lenkmoments bei Einsatz der zweiten querdynamischen Fahrereingangsgröße der lateralen Oberkörperposition verändert, wird auf einer 25 m Kreisbahn mit unterschiedlichen Fahrstilen gefahren. Zwei Testfahrer erhalten dazu die Fahrstilanweisungen „Hängen“, „Legen“ und „Drücken“. In Abbildung 5.2 sind die Ergebnisse in Form der gemittelten quasistationären Punkte (FC) dargestellt. Alle Datenpunkte einer Messung (ein Fahrer und Fahrstil) sind zur besseren Ablesbarkeit durch gestrichene Linien verbunden. Zunächst fällt auf, dass insgesamt nur fünf Messungen zu sehen sind, weil Fahrer 2 den Fahrstil „Hängen“ wegen mangelnder Erfahrung mit dieser Technik nicht absolviert hat. Gleichzeitig erreicht er im „Legen“ und „Drücken“ mit jeweils knapp 55 km/h deutlich höhere Geschwindigkeiten als Fahrer 1, der sich in keinem Fahrstil mehr als 45 km/h auf der konstanten Kreisbahn zutraut.

Auch bei Interpretation der Fahrstilanweisungen unterscheiden sich Fahrer 1 und 2. Wie an der Oberkörperneigung $\bar{\varphi}_{F,FC}$ in Abbildung 5.2c zu sehen ist, lehnt sich Fahrer 2 im „Drücken“ deutlich stärker als Fahrer 1 – sowie mit höherer Geschwindigkeit zunehmend – nach kurvenaußen. Hingegen zeigt der laterale Versatz nahe des Sitzpunkts in Abbildung 5.2d, dass Fahrer 2 beim „Drücken“ rund 3 cm in Richtung kurveninnen versetzt sitzt, während Fahrer 1 beim „Drücken“ auch den Sitzpunkt mit -8,5 cm deutlich nach kurvenaußen verschiebt. Im „Legen“ sitzen beide Fahrer mittig, Fahrer 2 kann den Oberkörper aber nicht gänzlich in Linie mit dem Motorrad halten. Im hängenden Fahrstil verschiebt Fahrer 1 den Sitzpunkt um 13 cm nach kurveninnen und stellt zudem etwas Oberkörperneigung in gleiche Richtung ein. Beide Fahrer halten den gewählten lateralen Versatz des Sitzpunkts während einer Messung konstant.

Die Veränderung des Fahrstils bewirkt deutliche Unterschiede in den für die Kreisfahrt einzustellenden Lenkmomenten. Die Differenzen sind über den gefahrenen Geschwindigkeiten konstant, was am konstanten vertikalen Abstand der Datenreihen in Abbildung 5.2a deutlich wird. Im „Hängen“ muss Fahrer 1 im Mittel 9 Nm stärker in Richtung kurveninnen lenken, während sein drückender Fahrstil eine mittlere Verschiebung des notwendigen Lenkmoments von 9 Nm nach kurvenaußen bewirkt. Das Lenkmoment ändert sich demnach in dieselbe Richtung, in welche der Fahrer das Gewicht verlagert.

Fahrer 2, der sich zwar mehr nach kurvenaußen lehnt, aber gleichzeitig den Sitzpunkt weiter kurveninnen hat als Fahrer 1, verändert den Lenkmomentbedarf beim „Drücken“ nur um durchschnittlich 3 Nm in Richtung kurvenaußen. Der Effekt aus der höheren

5.1 Stationäre Kurvenfahrt

Oberkörperneigung ist demnach eindeutig schwächer als der der Sitzpunktverschiebung. Teilweise ist der schwächere Effekt aber auch durch das etwa 30 kg geringere Gewicht von Fahrer 2 begründet. Dieses verursacht auch den im Mittel 1,5 Nm unterschiedlichen Lenkmomentbedarf zwischen dem ähnlich ausgeführten „Legen“ beider Fahrer.

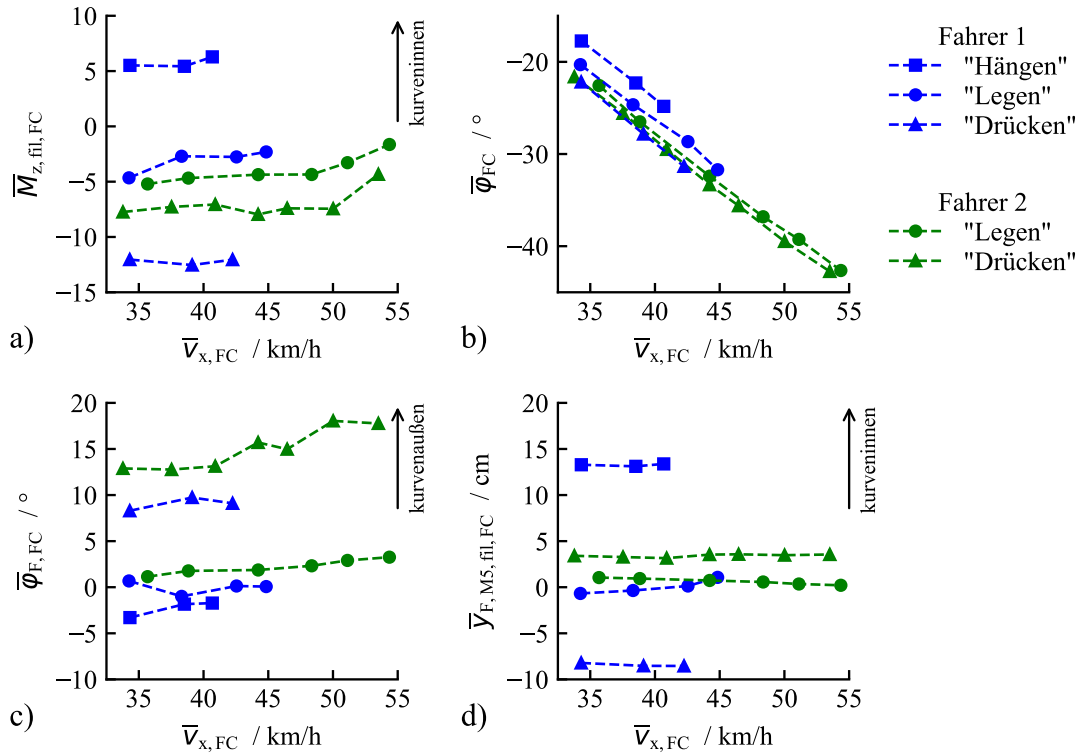


Abbildung 5.2: Effekt unterschiedlicher Fahrstile der Oberkörperposition auf Lenkmomentbedarf und Fahrzustand in quasistationärer Kreisfahrt auf der 25 m Kreisbahn.

Dass sich die Variation des Oberkörperschwerpunkts auch in einer Veränderung des Fahrzustands niederschlägt, ist am Verlauf des Rollwinkels $\bar{\varphi}_{FC}$ in Abbildung 5.2b erkennbar. Durch das Verschieben des Schwerpunkts nach kurveninnen kann die konstante Kurve von 25 m Radius bei gleicher Geschwindigkeit – und damit gleicher Querbewegung – mit einem betragsmäßig geringeren $\bar{\varphi}_{FC}$ durchfahren werden (Datenpunkte für „Hängen“ parallel zu geringeren Beträgen verschoben). Aus diesem Grund ermöglichen die Fahrstile „Hängen“ oder „Hanging-Off“ höhere maximale Kurvengeschwindigkeiten, wenn der maximal fahrbare Rollwinkel des Motorrads aufgrund von Design oder Reifengeometrie limitiert ist.

Die starke Beeinflussung des stationären Lenkmoments durch Veränderung der lateralen Fahrerposition macht deutlich, dass das Motorrad in Fahrsituationen der stationären Querdynamik nicht als System mit nur einem Eingang angenommen werden kann. Die für den 25 m Radius ermittelten Sensitivitäten wurden in der Mehrkörpersimulation nachgebildet und anschließend auch für größere Radien und höhere Geschwindigkeiten in gleicher Größenordnung bestätigt.

Neben dem betrachteten Einfluss der zweiten Fahrereingangsgröße gibt es jedoch weitere Umwelteinflüsse, die als Störungen auf das Übertragungsverhalten des Lenkmoments einwirken. Im Laufe der Fahrversuche wurden Lenkmomenteinflüsse aus Straßenneigung, Seitenwind, Reifenluftdruck, Reifentemperatur, Reifenverschleiß und Fahrbahnunebenheiten in Schräglage erfahren. In Relation zum stationären Lenkmomentbedarf im Bereich von einstelligen bis niedrigen zweistelligen Newtonmeter, der auf Kreisbahnen von 20 bis 100 m Radius gemessen wurde (siehe auch Abbildung 4.3), sind all diese Störungen von signifikanter Höhe. Die meisten sind außerdem schwer bis gar nicht beobachtbar. Es ist deshalb im realen Fahrbetrieb nur schwer möglich, aus Fahrereingaben eindeutig auf einen stationären querdynamischen Fahrzustand zu schließen, oder umgekehrt.

5.2 Transiente Kurvenfahrt

Zur Untersuchung der Fahrereingaben und des querdynamischen Übertragungsverhaltens in transienten Fahrmanövern werden sowohl Slalom- als auch Spurwechsel-Fahrmanöver absolviert. In deren Durchführung wird die Längsgeschwindigkeit jeweils konstant gehalten.

5.2.1 Einführung in die Slalomauswertung

Ziel des Slaloms ist es, das Motorrad sinusförmig, d.h. mit definierter Frequenz anzuregen. Mithilfe verschiedener Pylonenabstände (7, 14 und 21 m) und Geschwindigkeiten (30-100 km/h) werden Amplitude und Frequenz variiert. Für jede Durchfahrt werden die Amplituden der mit einem 2 Hz Tiefpass gefilterten Messsignale und die relativen Zeit- und Phasenverzüge zwischen Signalpaaren ermittelt. Die im Vergleich zur quasistationären Auswertung niedrigere Grenzfrequenz des Filters wird gewählt, weil dies sinusförmigere Signale bewirkt und damit die Berechnung der Kennzahlen verbessert. Die gewählte Grenzfrequenz von 2 Hz ist dabei noch mehr als doppelt so hoch wie die höchste gefahrene Frequenz des Slaloms von knapp 0,7 Hz. Das Vorgehen bei der Ermittlung von Amplituden, Zeit- und Phasenverzügen ist im Folgenden anhand einer beispielhaften Slalomfahrt erklärt.

In Abbildung 5.3 sind die Fahrereingaben und einige Fahrzustände bei Fahrt durch den 7 m Slalom mit 40 km/h dargestellt. Während hier ausgesprochen sinusförmige Signale vorliegen, gibt es andere Betriebspunkte, in denen insbesondere im Lenkmoment keine rein sinusförmige Anregung vorliegt. In der Auswertung wird deshalb die Frequenz einer Durchfahrt aus der mittleren Geschwindigkeit und dem Pylonenabstand errechnet. Die Signalamplituden werden über alle Maxima und Minima einer Durchfahrt gemittelt; in den Diagrammen in Abbildung

5.3 sind sie als rauteförmige Datenpunkte gezeigt und die resultierenden Mittelwerte sind jeweils oberhalb der Graphen angegeben.

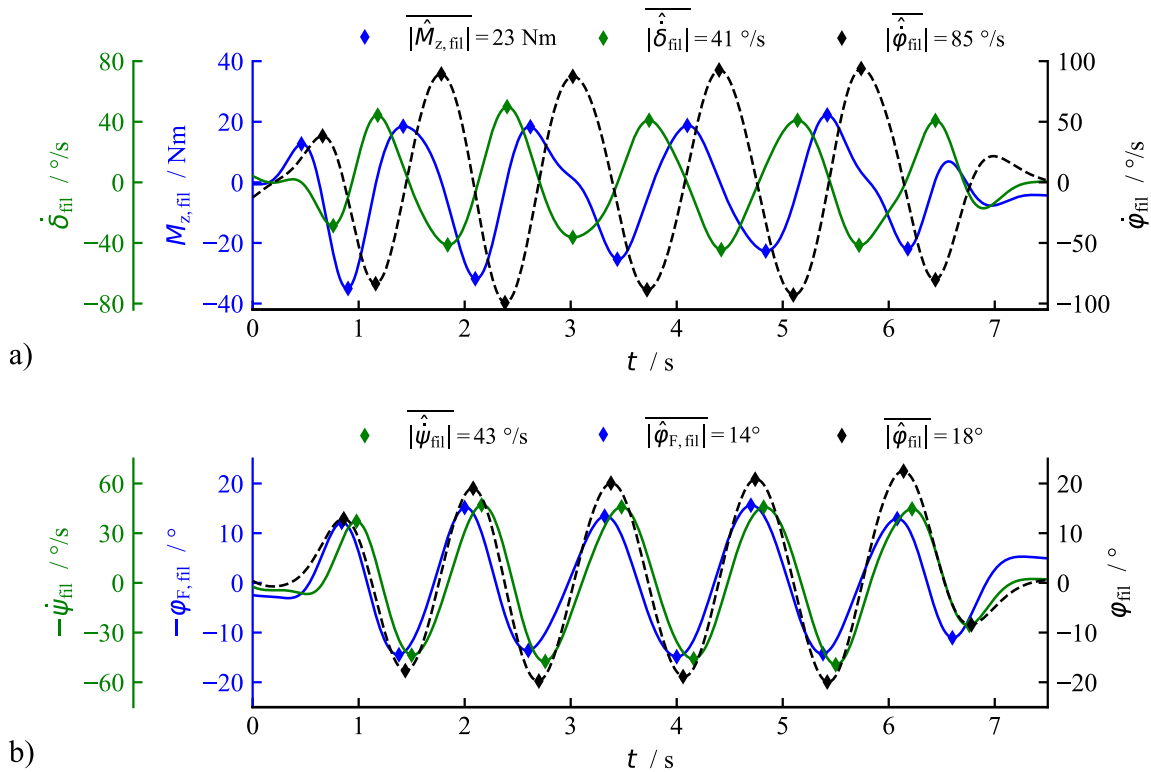


Abbildung 5.3: Zeitverlauf der Fahrzustände und Fahrereingaben im 7 m Slalom mit konstanter Geschwindigkeit 40 km/h. Mittlere Amplituden der Signale ausgewertet.

Der Zeitverzug zwischen zwei Signalen wird mittels der mathematischen Operation der diskreten Kreuzkorrelation berechnet. Bei dieser wird das erste Signal mit dem zeitumgekehrten zweiten Signal multipliziert. Das Ergebnis ist ein Maß für die Ähnlichkeit beider Signale, wobei der Wertebereich in normalisierter Form von -1 (der perfekten Antikorrelation) über 0 (für keine Korrelation) bis 1 (der perfekten Korrelation) reicht. Eine Auswertung der Ähnlichkeit für mehrere diskrete Zeitverschiebungen zwischen beiden Signalen erzeugt die Kreuzkorrelationsfunktion. Der Zeitpunkt, an dem diese Funktion ihr globales Maximum besitzt, stellt eine beste Näherung für den mittleren Zeitverzug der sinusähnlichen Signale der Slalomfahrten dar.

Für das Beispielmanöver in Abbildung 5.3a beträgt der Zeitverzug zwischen Lenkmomenteingabe $M_{z,fil}$ und Rollratenreaktion des Motorrads $\dot{\phi}_{fil}$ 0,30 s. Die Lenkrate $\dot{\delta}_{fil}$ verläuft für alle Slalomfahrten um 180° phasenversetzt zu $\dot{\phi}_{fil}$ (Antikorrelation kleiner 0,03 s in allen Fahrten); dies resultiert aus der in Abschnitt 3.1.1 festgelegten Ausrichtung der Koordinatensysteme, der zufolge ein in Kurvenrichtung eingedrehtes Vorderrad das entgegengesetzte Vorzeichen des Rollwinkels hat.

Damit ein positiver Rollwinkel φ_{fil} mit einer positiven Gierrate $\dot{\psi}_{\text{fil}}$ des Motorrads einhergeht, wird das Vorzeichen letzterer für die Darstellung in Abbildung 5.3b und die Korrelationsanalyse negiert. Im abgebildeten Slalom eilt φ_{fil} dem Verlauf von $-\dot{\psi}_{\text{fil}}$ um 0,08 s voraus. Die Oberkörperneigung $\varphi_{\text{F,fil}}$ wird für die Darstellung und Korrelationsanalyse ebenfalls negiert, weil die Fahrer ihren Oberkörper in allen Slalomfahrten immer entgegengesetzt zum Rollwinkel des Motorrads neigen. Das Signal von $-\varphi_{\text{F,fil}}$ eilt φ_{fil} im Beispiel in Abbildung 5.3b um 0,06 s voraus. Der laterale Versatz am Sitzpunkt des Fahreroberkörpers ist für alle Slalomfahrten nahe null und wird deshalb nicht betrachtet.

5.2.2 Fahrerbewegung im Slalom

Vor der Auswertung des Übertragungsverhaltens werden die Fahrstile in der Slalomfahrt betrachtet. Abbildung 5.4 zeigt auf der y-Achse die mittlere Amplitude der Oberkörperneigung für alle Fahrten der zwei Fahrer 2 und 3, die jeweils dieselben 7, 14 und 21 m Slalommanöver mit ihrem natürlichen Fahrstil, d.h. ohne spezifische Fahrstilanweisung absolviert haben. Eine Ausnahme stellen die zwei sternförmigen Datenpunkte mit 25° Amplitude der Oberkörperneigung dar, die Ergebnis eines bewusst drückenden Fahrstils sind; in diesen zwei Slalomfahrten beträgt die Rollwinkelamplitude 22° und 27° , der Fahrer hält seinen Oberkörper also aufrecht bzgl. dem Horizont. Alle Datenpunkte eines Fahrers für einen Pylonenabstand sind zur besseren Ablesbarkeit miteinander verbunden. Wie die Überlagerung der drei 7, 14 und 21 m Kurven je Fahrer in Abbildung 5.4 zeigt, korreliert die im natürlichen Fahrstil genutzte Amplitude der Oberkörperneigung in Näherung linear mit der Frequenz. Über alle Frequenzen neigt Fahrer 2 seinen Oberkörper etwa doppelt so stark wie Fahrer 3.




Abbildung 5.4: Amplitude der Oberkörperneigung der Fahrer 2 und 3 in allen Slalomfahrten.

Der zeitliche Versatz $t_{\varphi_{\text{F},\varphi}}$ zwischen dem negierten Signal der Fahreroberkörperneigung und dem Rollwinkel wird für alle Slalomfahrten ermittelt, die mit mindestens 5° Amplitude der Oberkörperneigung gefahren wurden (für niedrigere Werte liefert die Kreuzkorrelation kein belastbares Ergebnis). In Abbildung 5.5 ist $t_{\varphi_{\text{F},\varphi}}$ über der Geschwindigkeit des Slaloms

dargestellt, mit der eine deutliche negative Korrelation vorliegt, d.h. mit zunehmender Geschwindigkeit nimmt $t_{\varphi_F, \varphi}$ ab. Ein Zeitverzug von 0 s bedeutet, dass sich der Fahrer exakt gegenläufig zum Rollwinkel des Motorrads neigt. Positive Zeitverzögerungen bedeuten ein Vorseilen und negative ein Nacheilen der Fahrerbewegung. Bei niedrigen Geschwindigkeiten eilt die Fahrerbewegung dem Rollwinkel leicht voraus, ab 50 km/h ist hingegen eine nacheilende Bewegung des Fahrers vorhanden. Trotz ihrer unterschiedlichen Neigungsamplituden zeigen beide Fahrer – in den wenigen Datenpunkten, die für Fahrer 3 ausgewertet werden können – gleiches Timing der Oberkörperneigung.




Abbildung 5.5: Zeitverzug zwischen negierter Fahrerobkörperneigung und Rollwinkel in allen Slalomfahrten mit mindestens 5° Amplitude der Oberkörperneigung. Positive Werte stehen für das Vorseilen der Fahrerbewegung.

Der Rollwinkel, der in Abbildung 5.5 als Referenz für den Zeitverzug der Fahrerbewegung herangezogen wird, eilt selbst zwischen 0,45 und 2 s der Lenkmomenteingabe des Fahrers hinterher. Die Fahrerbewegung kommt also eindeutig später als die Lenkmomenteingabe. Es wird deshalb für das transiente Slalommanöver geschlussfolgert, dass die Oberkörperneigung eine Fahrerreaktion und keine aktive Fahrereingabe darstellt. Die annähernd gegenläufige Neigung von Fahrer und Motorrad unterstützt die These aus den Literaturquellen in Abschnitt 2.1, dass die Oberkörperneigung durch Komfort und Kontrollierbarkeit motiviert ist, denn die Kompensation der Fahrzeugneigung durch nahezu gegenläufige Neigung des Oberkörpers ermöglicht ein stärker horizontiertes Blickfeld.

5.2.3 Übertragungsverhalten des Lenkmoments im Slalom

Folgend wird das Übertragungsverhalten der Lenkmomenteingabe in den definierten transienten Fahrzuständen des Slaloms untersucht. Dabei liegt ein besonderes Augenmerk darauf, inwiefern der Unterschied im Fahrstil beider Fahrer dieses beeinflusst. Zuerst wird die Verstärkung des Lenkmomenteingangs betrachtet. Sie ist als das Amplitudenverhältnis $A_{M_z, \dot{\varphi}}$ von Rollrate und Lenkmoment entsprechend Formel (5.1) definiert.

$$A_{M_z, \dot{\varphi}} = \frac{|\widehat{\varphi}_{\text{fil}}|}{|\widehat{M}_{z, \text{fil}}|} \quad (5.1)$$

Die Verstärkung $A_{M_z, \dot{\varphi}}$ quantifiziert das Handling des Motorrads in transients Kurvenfahrt, wobei ein hoher Wert hohe Agilität und damit leichtes Handling bedeutet. Die Agilität korreliert eindeutig mit der Geschwindigkeit der Slalomfahrt, über der $A_{M_z, \dot{\varphi}}$ in Abbildung 5.6 für alle Slalommanöver aufgetragen ist. Die Frequenz zeigt hingegen keinen Einfluss auf die Verstärkung des Lenkmoments. Charakteristisch am Verlauf von $A_{M_z, \dot{\varphi}}$ in Abbildung 5.6 ist die höchste Agilität im Bereich von 30 bis 35 km/h. Es handelt sich um den Beginn des eigenstabilen Bereichs der Kippdynamik des Versuchsmotorrads. Mit weiter zunehmender Geschwindigkeit nimmt die Verstärkung des Lenkmoments ab, das Motorrad wird unhandlicher. Dieser Effekt wird hauptsächlich durch das Ansteigen der stabilisierenden gyroskopischen Momente der Räder unter Rollbewegung verursacht.

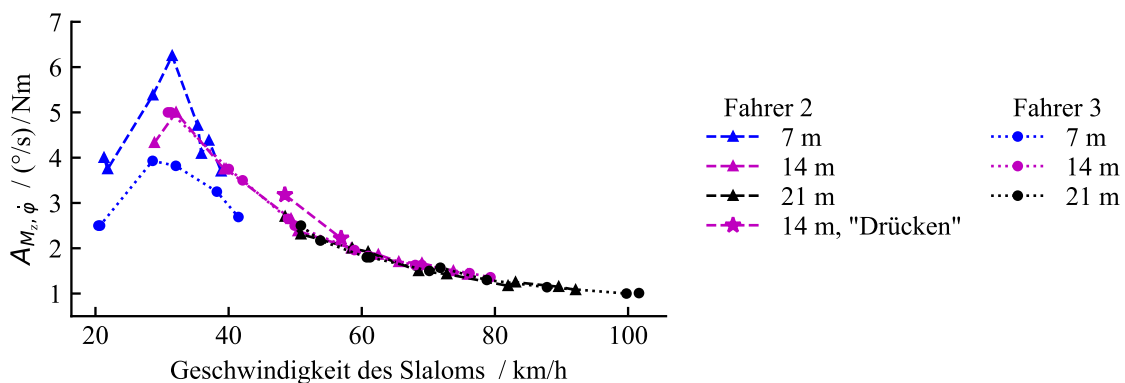


Abbildung 5.6: Verstärkung von Lenkmomenteingang zu Rollratenzustand in Abhängigkeit der Längsgeschwindigkeit für alle Slalomfahrten.

Ein Unterschied in der Verstärkung des Lenkmoments zwischen beiden Fahrern ist besonders für den in Abbildung 5.6 blau dargestellten 7 m Slalom zu erkennen. Dieser wird durch die unterschiedlichen Fahrstile verursacht. Fahrer 2 erfährt in diesem Slalom ein zwischen 20 % (bei knapp 40 km/h) und 60 % (im Punkt der maximalen Verstärkung) höheres $A_{M_z, \dot{\varphi}}$ als Fahrer 3. Anhand der Annäherung der Verstärkungen beider Fahrer im 7 m Slalom bei 40 km/h ist zu erkennen, dass der Einfluss der Oberkörperbewegung mit zunehmender Geschwindigkeit abnimmt. Dass sich die Verstärkungen beider Fahrer bei 30 bis 40 km/h im 14 m Slalom nicht sichtbar unterscheiden (im Gegensatz zum 7 m Slalom bei gleicher Geschwindigkeit), liegt an den geringen Amplituden der Oberkörperneigung.

Beim Vergleich der absoluten Lenkmomentamplituden beider Fahrer im 7 m Slalom wird klar, dass Fahrer 2 die höhere Agilität nicht erfährt, weil er identische Lenkmomente aufbringt wie Fahrer 3. Dies liegt am stärker drückenden Fahrstil von Fahrer 2, der höhere Rollwinkel des

Motorrads erforderlich macht, um den Slalom bei gleicher Geschwindigkeit zu absolvieren. Der vergrößerte Rollwinkelbedarf erfordert wiederum höhere Rollraten, welche den Vorteil der höheren Verstärkung in diesem konkreten Fall genau aufzehren.

Die Lenkmomentverstärkung bei stark drückendem Fahrstil im 14 m Slalom, dargestellt durch die sternförmigen Datenpunkte in Abbildung 5.6, ist im Mittel um 14 % erhöht. Auch hier ist der Trend erkennbar, dass die Differenz aufgrund des unterschiedlichen Fahrstils mit zunehmender Geschwindigkeit sinkt. Ab 60 km/h kann deshalb davon ausgegangen werden, dass selbst extreme Variationen des Fahrstils keinen Einfluss mehr auf die Verstärkung des Lenkmoments in transienten Fahrmanövern nehmen.

Die zweite zu betrachtende Eigenschaft des transienten Lenkübertragungsverhaltens ist die Verzögerung zwischen einer Lenkmomenteingabe und der Rollratenreaktion. Diese korreliert mit der Geschwindigkeit und ist abhängig von der Rollratenamplitude $\hat{\varphi}$. Deshalb wird der aus der Kreuzkorrelation ermittelte Phasenverzug $\alpha_{M_z, \dot{\varphi}}$ für die Darstellung in Abbildung 5.7 mit $\hat{\varphi}$ normiert. Positive Werte in allen Datenpunkten bedeuten, dass das Lenkmoment der Rollrate immer vorausseilt. In Abbildung 5.7 ist eine asymptotische Abnahme der normierten Verzögerung mit zunehmender Geschwindigkeit sichtbar. Diese ist besonders im instabilen Bereich der Kippdynamik bis 30 km/h so groß, dass eine logarithmische Skala gewählt wurde.




Abbildung 5.7: Mit der Rollratenamplitude normierter Phasenverzug von Lenkmomenteingang zu Rollratenzustand für alle Slalomfahrten. Positive Werte stehen für das Vorausseilen des Lenkmoments.

Über alle Geschwindigkeiten erfährt Fahrer 2 – mit der höheren Amplitude der Oberkörperbewegung – niedrigere normierte Verzögerungen seiner Lenkmomenteingabe als Fahrer 3. Die sternförmigen Datenpunkte der Slalomfahrt mit ausgeprägtem „Drücken“ in Abbildung 5.7 verdeutlichen die Verringerung der normierten Verzögerung mit zunehmender Oberkörperneigung. Wenn die Absolutwerte der Verzögerung ausgewertet werden, besteht jedoch kein signifikanter Unterschied zwischen den Fahrern aufgrund der Fahrstile, weil ein Anstieg der Rollratenamplitude im Fahrstil „Drücken“ die Differenz der normierten Verzögerung

ausgleicht. Im Mittel ist die Lenkmomenteingabe von Fahrer 2 nur um 0,03 s bzw. 5° weniger verzögert als die von Fahrer 3.


In absoluten Zahlen beträgt der Zeitverzug zwischen Lenkmomenteingabe und Rollratenreaktion 0,5 bis 1,3 s im Bereich der instabilen Kippdynamik (kleiner 30 km/h). In jeglichen Slalommanövern mit 50 km/h oder mehr ist der Zeitverzug kleiner als 0,2 s.

Das Übertragungsverhalten zwischen querdynamischen Fahrzuständen, wie z.B. von Rollwinkel und Gierrate, zeigt keine Beeinflussung durch unterschiedliche Fahrstile.

5.2.4 Fahrerbewegung im Spurwechsel

Während Slalommanöver gut für die Identifikation des querdynamischen Übertragungsverhaltens geeignet sind, haben sie jedoch wenig Relevanz für die Fahrt im Straßenverkehr. Anhand von realistischen transienten Fahrmanövern wird deshalb geprüft, ob das in Abschnitt 5.2.2 beobachtete Fahrerverhalten der Oberkörperbewegung Bestand hat.

Es werden einfache und doppelte Spurwechsel (SW) in je drei verschiedenen Geometrien gefahren, die in der Skizze in Abbildung 5.8 spezifiziert sind. Dank der verschiedenen Geometrien kann hochdynamische Fahrt bei unterschiedlichen Geschwindigkeiten gemessen werden. Jedes der insgesamt sechs Szenarien beginnen die Fahrer mit moderater Geschwindigkeit und steigern diese in mehreren Durchfahrten bis sie ihre persönliche Grenzgeschwindigkeit erreichen. Die gestellten SW-Gassen werden abwechselnd in beide Richtungen befahren.



Geometrien von Cossalter & Sadauckas [73]: „TÜV Slow“, „MDRG Touring“, „TÜV Fast“

Abbildung 5.8: Skizze der drei Geometrien für einfache und doppelte Spurwechselmanöver.

In allen SW-Durchfahrten wenden die Fahrer ihren natürlichen Fahrstil an. Sie nutzen beide ausschließlich Oberkörperneigung φ_F und keine laterale Verschiebung des Sitzpunkts. Die Neigung findet immer entgegengesetzt zum Rollwinkel φ des Motorrads statt. Die Beträge der Amplituden der Oberkörperneigung und des Rollwinkels im ersten Richtungswechsel (Einfahrt in den SW) sind in Abbildung 5.9 aufgetragen. Fahrer 1 durchfährt die gestellten SW-Gassen nahe der Ideallinie und benötigt daher weniger Rollwinkel als Fahrer 2, der eine weitere

Fahrlinie wählt. Bezogen auf den Rollwinkel nutzen beide Fahrer ähnliche Amplituden der Oberkörperneigung.




Abbildung 5.9: Betrag der ersten Amplituden von Fahreroberkörperneigung und Rollwinkel bei einfachen und doppelten Spurwechseln (SW).

Zur Analyse des Timings der Fahrerbewegung bei der Einfahrt in den SW wird der zeitliche Versatz $t_{\varphi_F, \varphi}$ zwischen den ersten Signalamplituden von φ_F und φ ausgewertet; ein positiver Wert bedeutet dabei ein Vorseilen von φ_F . In Abbildung 5.10 sind die Werte $t_{\varphi_F, \varphi}$ für alle SW über der Geschwindigkeit dargestellt. Es zeigt sich ein sehr ähnliches Verhalten der Zeitverzögerung wie im Slalom: bis zu einer Geschwindigkeit von 50 km/h wird der Oberkörper leicht vorseilend bis zeitgleich mit dem Rollwinkel des Motorrads geneigt, darüber hinaus ist die Fahrerbewegung reaktiv bzgl. des Rollwinkels. Außerdem weisen beide Fahrer trotz unterschiedlicher absoluter Oberkörperneigung wieder ähnliches Timing auf. Für Fahrer 1 streuen die Werte stärker als für Fahrer 2.




Abbildung 5.10: Zeitverzug zwischen den ersten Amplituden von Fahreroberkörperneigung und Rollwinkel bei einfachen und doppelten Spurwechseln (SW). Positive Werte stehen für das Vorseilen der Fahrerbewegung.

Das Übertragungsverhalten des Lenkmoments und anderer Fahrdynamikzustände in den SW ist deckungsgleich mit dem im Slalom identifizierten Verhalten (siehe Abschnitt 5.2.3).

5.2.5 Physische Betrachtung der Fahrerbewegung

Wie die in Abschnitt 5.2.3 ausgewerteten Slalomversuche zeigen, kann die Oberkörperbewegung des Fahrers die Verstärkung des Lenkmoments in transienten Manövern nur bei

Geschwindigkeiten kleiner 60 km/h signifikant beeinflussen. Es kommt hinzu, dass eine vergrößerte Verstärkung durch den Fahrstil „Drücken“ vom gleichzeitig ansteigenden Rollwinkelbedarf quasi vollständig kompensiert wird und das absolute Lenkmoment im Slalommanöver für unterschiedliche Fahrstile identisch ist – trotz nominell höherer Verstärkung liegt im Manöver gleiches absolutes Handling vor. Folgerichtig begründen verschiedene Literaturquellen den Fahrstil „Drücken“, der gleichermaßen im Spurwechsel vorhanden ist, nicht mit verbessertem Handling, sondern nennen stattdessen erhöhten Komfort und bessere Übersicht durch die möglichst aufrechte Haltung des Oberkörpers als Motivationen.

Dieser Abschnitt soll eine weitere, physische Perspektive auf die Motivation des Fahrstils im Slalom eröffnen. Es ist anzunehmen, dass sich das vom Fahrer erlebte Handling für unterschiedliche Fahrstile vom gemessenen Handling unterscheidet, weil durch die Relativbewegung zwischen Fahreroberkörper und Motorrad andere physische Anstrengungen beim Stellen des gleichen Lenkmoments entstehen. Die Bewegung des Motorrads unter dem Fahrer im Fahrstil „Drücken“ kann aufgrund der Massenträgheit zum Aufbringen eines Lenkmoments genutzt werden. Ob dieser Effekt in den Slalomfahrten aufgetreten ist, wird durch die Analyse des Phasenwinkels α_{M_z, φ_F} zwischen Lenkmoment M_z und Neigungswinkel des Oberkörpers φ_F überprüft.

Anhand der drei Grenzfälle in Abbildung 5.11a wird zunächst die Bedeutung der Phasenwinkel α_{M_z, φ_F} von 90° , 0° und -90° erläutert.

- Ein um 90° vorauseilendes M_z bedeutet, dass dieses synchron mit der Rate der Oberkörperneigung $\dot{\varphi}_F$ verläuft; der Fahrer zieht am Lenkerende, von welchem er sich wegbewegt, und drückt am Lenkerende, auf welches er sich zubewegt. Bei diesem Timing von Fahrerbewegung und Lenkeingabe wird die Massenträgheit nur teilweise ausgenutzt (bei abnehmendem $|\dot{\varphi}_F|$).
- Die synchron verlaufenden Amplituden von M_z und φ_F bei 0° Phasenwinkel bedeuten einen genau gegenläufigen Verlauf von M_z und der Beschleunigung der Oberkörperneigung $\ddot{\varphi}_F$; der Fahrer drückt am Lenkerende, von dem er sich wegbeschleunigt und zieht am Lenkerende, zu dem er sich hinbeschleunigt. In diesem Fall liegt die optimale Ausnutzung der Massenträgheit vor.
- Ist M_z um -90° zu φ_F verschoben, liegt es genau gegenläufig zur $\dot{\varphi}_F$; der Fahrer drückt sich von einem Lenkerende weg und zieht sich zum anderen heran, bis er die maximale Oberkörperneigung erreicht hat. Hier wird die Massenträgheit wieder nur teilweise ausgenutzt (bei zunehmendem $|\dot{\varphi}_F|$).

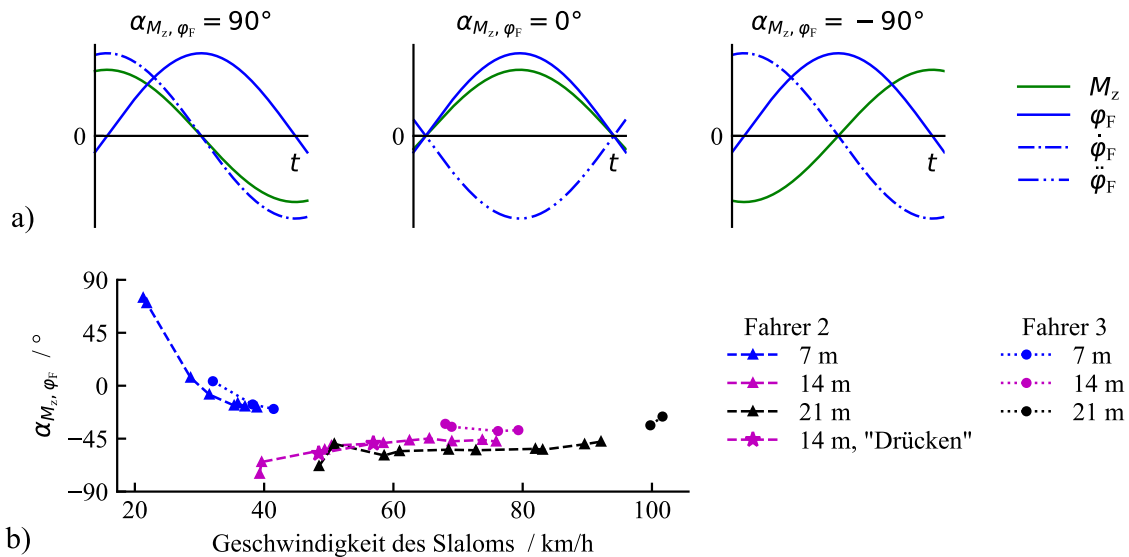


Abbildung 5.11: Phasenverzug zwischen Lenkmomenteingabe und Fahreroberkörperneigung: a) Grenzfälle des 90° Vorauseilen, Synchronität und 90° Nacheilen schematisch dargestellt, b) Werte für alle Slalomfahrten.

In Abbildung 5.11b ist α_{M_z, φ_F} für alle Slalomfahrten mit mindestens 5° Amplitude in φ_F dargestellt. Es zeigt sich, dass im 7 m Slalom für Geschwindigkeiten zwischen 30 und 40 km/h ein Phasenwinkel nahe 0° und damit eine hohe Ausnutzung der Massenträgheit für beide Fahrer vorliegt. Für alle höheren Geschwindigkeiten bzw. den 14 und 21 m Slalomfahrten liegt α_{M_z, φ_F} zwischen 0 und -90°, bei niedrigster Geschwindigkeit von 20 km/h steigt α_{M_z, φ_F} in Richtung 90°. Es liegt damit immer mindestens eine teilweise Ausnutzung von Effekten der Massenträgheit vor, wenn die Fahrer im Slalom den Fahrstil „Drücken“ mit dem in Abschnitt 5.2.2 gezeigten Timing – nahezu exakt gegenläufig zum Rollwinkel des Motorrads – einsetzen. Ein positiver Effekt auf das vom Fahrer empfundene Handling aufgrund dieses Fahrstils ist demnach plausibel und stellt daher einen weiteren möglichen Beweggrund für den Einsatz des „Drückens“ in transienten Fahrmanövern dar.

5.3 Schlussfolgerung

Im eigenstabilen Bereich der Kippdynamik des Motorrads wird in Fahrversuchen beobachtet, dass von den zwei Fahrereingaben zur Beeinflussung der Querdynamik nur das Lenkmoment vom Fahrer als aktive Eingangsgröße genutzt wird. In ihrer Oberkörperposition zeigen die Fahrer in den betrachteten transienten Spurwechsel- und Slalommanövern reaktives Verhalten bzgl. des Rollwinkels. Die Fahrerbewegung wird deshalb im folgenden Verlauf der Arbeit nicht mehr als querdynamische Fahrereingangsgröße, sondern als Messgröße des Fahrerverhaltens bezeichnet. Diese Aussage mag sich ändern, wenn die Motorradfahrt auf Rennstrecken

untersucht werden würde, sie stellt jedoch keinen Anwendungsfall der Algorithmen in dieser Arbeit dar.

In stationärer Kurvenfahrt beeinflusst die laterale Position des Fahreroberkörpers das Übertragungsverhalten des Lenkmoments signifikant. Zur sinnvollen Interpretation des Lenkmoments in diesen Fahrzuständen muss die Fahrerposition demnach bekannt sein. Jedoch bestehen weitere Störeinflüsse, die in relevanter Größenordnung auf das Lenkmoment einwirken und die teilweise nicht beobachtbar sind. Aus diesem Grund wird eingeschätzt, dass eine laterale Trajektorienprädiktion in quasistationären Fahrsituationen keine Verbesserung durch die Messung von Lenkmoment und Fahrerposition erfährt.

In transienten querdynamischen Fahrmanövern eilt die Lenkmomenteingabe des Fahrers zwischen 0,1 s bei hohen Geschwindigkeiten und 0,5 s bei 30 km/h gegenüber der Rollratenreaktion des Motorrads voraus. Eine Trajektorienprädiktion, die auf einem physikalischen Modell des Motorrads mit Lenkmomenteingang basiert, kann ihre Vorausschauzeit theoretisch um diese Zeitbeträge gegenüber einem Prädiktionsmodell ohne Lenkmomentmessung vergrößern. Der Einfluss der Fahreroberkörperbewegung auf die Verstärkung des Lenkmoments ist dabei in den meisten Fahrzuständen vernachlässigbar gering. Selbst extreme Fahrstilausprägungen zeigen oberhalb von 60 km/h keinen Einfluss mehr auf das Übertragungsverhalten. Der Zeitverzug der Lenkmomenteingabe wird durch unterschiedliches Fahrerverhalten der Oberkörperbewegung nicht signifikant verändert.

Zusammengefasst kann die Information der Fahrerbewegung in transienten querdynamischen Fahrmanövern nicht gewinnbringend für eine physikalische Trajektorienprädiktion eingesetzt werden, weil diese reaktiv ist. Auch die Messung des Lenkmoments weist mit einer Vorlaufzeit zwischen 0,1 s und 0,5 s nur ein geringes Verbesserungspotential bzgl. des erreichbaren Prädiktionshorizonts auf. Es wird sich deshalb gegen die Realisierung eines physikalischen Modells zur lateralen Trajektorienprädiktion entschieden.

Es verbleibt die Untersuchung eines manöverbasierten Algorithmus der Trajektorienprädiktion, der u.a. die neuartigen Messgrößen der Zustandsgrößen der Lenkung, der Lenkmoment-Fahrereingabe und des Fahrerverhaltens in der Oberkörperbewegung interpretiert, um daraus Informationen über die Fahrerabsicht zu gewinnen. Damit dafür in Kapitel 7 eine Methode des maschinellen Lernens erfolgreich angewendet werden kann, sind Messdaten realen Fahrerverhaltens von verschiedenen Fahrern in möglichst diversen Fahrsituationen erforderlich. Die diesbezüglich durchgeführte Datenerhebung ist im folgenden Kapitel 6

5.3 Schlussfolgerung

beschrieben. In Abschnitt 8.4 wird die Frage zur Bedeutung der neuartigen Messgrößen für die laterale Trajektorienprädiktion aus Sicht eines manöverbasierten Algorithmus beantwortet.

6 Datenerhebung zum Realfahrverhalten

Um einen Datensatz zum Training eines maschinell gelernten Algorithmus für die manöverbasierte laterale Trajektorienprädiktion aufzunehmen, werden mit dem in Kapitel 4 beschriebenen Versuchsmotorrad Messfahrten im öffentlichen Straßenverkehr durchgeführt. Abschnitt 6.1 erläutert die Zielsetzung und Durchführung der Datenerhebung. Anschließend ist in Abschnitt 6.2 die Methode der Manöversegmentierung beschrieben, die zur systematischen Analyse des Datensatzes, und zur späteren Auswertung der Prädiktionsgüte in Kapitel 8, eingesetzt wird. Die Fahrweisen und Fahrstile der Testfahrer sowie die Korrelation der zusätzlichen Fahrerhaltens-Messgröße des Kopfdrehwinkels mit der Kurvenfahrt werden in den Abschnitten 6.3 und 6.4 untersucht.

6.1 Zielsetzung und Durchführung

Wie in Abschnitt 2.1 eingeführt, können zwischen Motorradfahrern große Unterschiede im Fahrerverhalten bestehen, weil sich Erfahrung, Können und Vorlieben unterscheiden. Es sollen deshalb Fahrdaten von möglichst vielen Testfahrern erhoben werden, damit ein repräsentativer Datensatz entsteht. Das natürliche Fahrerverhalten kann dadurch verfälscht werden, dass die Fahrer aufgrund der speziell applizierten Messtechnik nicht mit ihrem eigenen, gewohnten Motorrad fahren können, sondern das Versuchsmotorrad verwenden müssen. Eine dedizierte Eingewöhnungsfahrt ist aufgrund begrenzter Zeit nicht möglich, es wird aber vor der Fahrt eine ausführliche Erläuterung zur Bedienung des Motorrads gegeben. Während einer Messfahrt von etwa zwei Stunden Dauer wird eine schnelle Eingewöhnung erwartet.

Um einen möglichst diversen Datensatz zu erhalten, unterscheidet sich die Streckenführung jeder Messfahrt. Damit wird vorgebeugt, dass sich ein maschinell gelernter Algorithmus auf eine bestimmte Streckencharakteristik überanpasst. Die Diversifizierung der Routen ist einfach umsetzbar, weil die Messfahrten aus organisatorischen Gründen an verschiedenen Ausgangspunkten starten. Weil der Fokus dieser Arbeit auf der Kurvenfahrt des Motorrads liegt, werden die Routen mit einem hohen Anteil an Landstraßen mit kurviger Streckenführung geplant. Durchfahrten durch Orte und kleinere Städte sind im dicht besiedelten Süddeutschland ebenfalls regelmäßig vorhanden. Fahrten auf Bundesstraßen oder Autobahnen kommen mit einem Streckenanteil von etwa 25 % im Mittelwert über alle Routen vor.

Neben der Bedienung des Versuchsmotorrads wird jedem Testfahrer vor Fahrtbeginn der Zweck der Datenerhebung erläutert. Dabei wird betont, dass natürliches Fahrerverhalten

untersucht wird und demnach keine besonderen Handlungen absolviert werden sollen. Damit die Fahrer ihren eigenen Vorlieben entsprechend fahren, werden sie nicht begleitet. Die fahrerindividuelle Route wird ihnen stattdessen auf einem Navigationsgerät angezeigt. Sie gilt als Empfehlung für eine interessante Fahrstrecke mit einer Fahrdauer von etwa zwei Stunden. Von ihr darf abgewichen werden, wenn z.B. Straßensperrungen auftreten. Nach der Klärung etwaiger Rückfragen füllt jeder Testfahrer einen Fragebogen zu seinen persönlichen Daten, Fahrgewohnheiten und Vorlieben aus; dieser kann in Anhang A.4 eingesehen werden. Als letzter Schritt vor Beginn einer Messfahrt werden die optischen Marker auf dem Helm des Testfahrers angebracht und die Weste zur Messung der Oberkörperposition angezogen. Nach der Messfahrt werden die Testfahrer hinsichtlich besonderer Fahrsituationen oder anderer Auffälligkeiten befragt, damit diese in der Auswertung speziell berücksichtigt werden können. Bei Dauerregen findet aus Sicherheitsgründen keine Messfahrt statt.

In Summe werden 74 h bzw. eine Gesamtstrecke von 4900 km Motorradfahrt aufgezeichnet. Von den insgesamt 21 Testfahrern ist eine Person für die Aufzeichnung von 45 % aller Daten verantwortlich, die übrigen 55 % entfallen zu gleichen Teilen auf die 20 anderen Fahrer.

Basierend auf den Fragebögen können die Testfahrer entsprechend der in Abbildung 6.1 gezeigten Verteilungen charakterisiert werden; die Boxplots in Abbildung 6.1a zeigen dabei diejenigen Werte als Ausreißer an, die weiter als einen Interquartilsabstand über dem 75 %-Quantil oder unter dem 25 %-Quantil liegen. Mit Fahrern im Alter zwischen 26 und 68 Jahren und mit 5 bis 50 Jahren Führerscheinalter ist ein breites Spektrum an Fahrerfahrung in den Daten abgebildet. Der Median der letztjährigen Fahrleistung liegt mit 5000 km deutlich über der vom Kraftfahrt-Bundesamt angegebenen durchschnittlichen Fahrleistung von 2096 km für Motorräder im Jahr 2022 in Deutschland [91]. Das kann damit begründet werden, dass sich Fahrer, die gerne und oft Motorrad fahren, eher für eine Teilnahme an der Datenerhebung entscheiden. Trotzdem sind auch zwei Testfahrer vorhanden, die keine Fahrpraxis in der vergangenen Motorradsaison aufweisen.

In Abbildung 6.1b sind die Antworten auf drei Fragen dargestellt, bei denen sich die Fahrer auf einer fünfstufigen Skala eingeordnet haben. Bzgl. der Dynamik der persönlichen Fahrweise – zwischen komfortorientiert und sportlich – ordnen sich elf Fahrer in der Mitte der Skala ein, fahren also abwechselnd sportlich und komfortorientiert. Insgesamt zeigt sich für die 21 Fahrer eine deutliche Tendenz zu sportlicher Fahrweise. Hingegen besteht in der Risikoabwägung eine Tendenz zu sicherheitsorientiertem Verhalten, kein Fahrer gibt an „risikofreudig“ zu fahren. Ganze 17 von 21 Testfahrern geben an, dass sie sich im fahrdynamischen Grenzbereich sehr oder völlig sicher fühlen; von diesen haben neun Fahrer regelmäßige Rennstreckenerfahrung und damit gesicherte Erfahrung in diesem Gebiet.

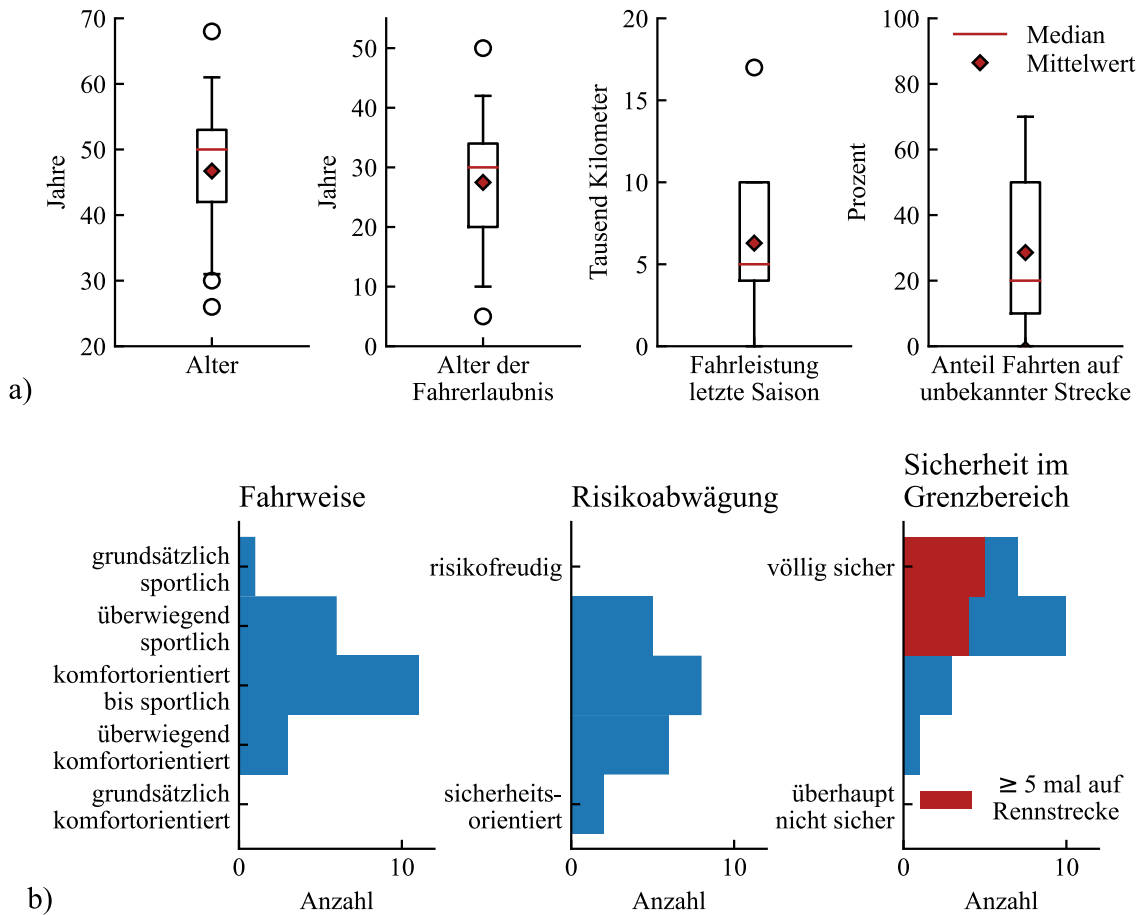


Abbildung 6.1: Charakterisierung der 21 Testfahrer der Datenerhebung: a) Verteilungen des Alters und der Fahrerfahrung, b) Selbsteinschätzung des Fahrverhaltens.

Die Eigenschaften des erhobenen Datensatzes hinsichtlich der enthaltenen Querdynamik und der Diversität des Fahrerverhaltens werden in den zwei folgenden Abschnitten analysiert.

6.2 Manöversegmentierung

Um die systematische Analyse der Kurvenfahrten in den Messfahrten zu vereinfachen und eine anschauliche Beschreibung der Fahrdaten zu ermöglichen, wird eine Klassifizierung der zeitkontinuierlichen Messdaten in querdynamische Manöversegmente (MS) durchgeführt. Zuerst wird im Folgenden das Konzept der querdynamischen Manöversegmente erläutert. Anschließend wird dessen Realisierung mit einem Zustandsautomaten beschrieben und zuletzt kann die Charakteristik der Querdynamik im Datensatz anhand der MS beschrieben werden.

6.2.1 Konzept querdynamischer Manöversegmente

Als MS werden zeitliche Abschnitte der Motorradfahrt mit charakteristischer Fahrdynamik bezeichnet. Das Ziel ist, dass mit einer geringen Anzahl an MS jedes beliebige querdynamische Fahrmanöver sinnvoll beschrieben werden kann. Hierbei bestehen für den großen Datensatz

aus dem öffentlichen Straßenverkehr die Herausforderungen, dass nicht alle darin enthaltenen Manöver bekannt sind und eine manuelle Annotation von MS zu aufwendig ist. Bartolozzi et al. [92] nutzen deshalb einen unbeaufsichtigt lernenden Clustering Algorithmus, der basierend auf den Fahrzuständen Rollwinkel, -rate und -beschleunigung sechs MS der Querdynamik identifiziert; zwei MS für die Geradeausfahrt und quasistationäre Kurvenfahrt sowie vier transiente MS. Jedoch ist für die Interpretation der – vom Algorithmus identifizierten – MS selbst auf einer kurzen Teststrecke, auf der die Methode getestet wird, ein hoher Aufwand nötig. Weil das Verhalten der Segmentierung auf neuen Daten außerdem nicht sicher vorhersehbar ist, wird sich gegen den Einsatz einer unbeaufsichtigten Methode der Segmentierung entschieden.

Basierend auf Expertenwissen und ausgewählten Fahrdynamikanalysen wird ein Zustandsautomat zur Klassifizierung der Messdaten in MS entwickelt. Dieser verarbeitet die Fahrdaten sequenziell und entscheidet in jedem Zeitpunkt über das vorliegende MS. Weil die Übergangsbedingungen zwischen den Zuständen im Zustandsautomat eindeutig festgelegt sind, ist diese Form der Klassifikation gut nachvollziehbar. Die Definition querdynamischer MS geschieht in Anlehnung an die Manöver-Primitive aus der Arbeit von Magiera [38], die in Abschnitt 2.1 vorgestellt wurde. Weil die Querdynamik des Motorrads eng mit der Rollbewegung verknüpft ist, werden Rollwinkel φ und Rollrate $\dot{\varphi}$ zur Charakterisierung der MS verwendet.

In den zwei Diagrammen in Abbildung 6.2 ist der querdynamische Zustandsraum zu sehen, der durch φ und $\dot{\varphi}$ aufgespannt wird. Abbildung 6.2b zeigt beispielhaft die Trajektorien der Rolldynamik bei der Fahrt durch eine 180°-Linkskurve (pink) und einen einfachen Spurwechsel nach links (schwarz). In Abbildung 6.2a ist die Aufteilung des Rolldynamik-Zustandsraums in MS dargestellt. Als quasistationäre querdynamische MS werden die Geradeausfahrt (S – „straight“) und quasistationäre Kurvenfahrt (C – „constant curve“) unterschieden. Sie liegen vor, wenn $|\dot{\varphi}|$ unterhalb eines Schwellwerts liegt, denn kleine Rollraten sind Ausdruck der Stabilisierungstätigkeit des Fahrers und sollen nicht zum Verlassen eines quasistationären MS führen. Für die Abgrenzung von S und C besteht keine allgemeingültige Definition; die Wahl des Grenzwerts hängt von der Anwendung der Manöversegmentierung ab.

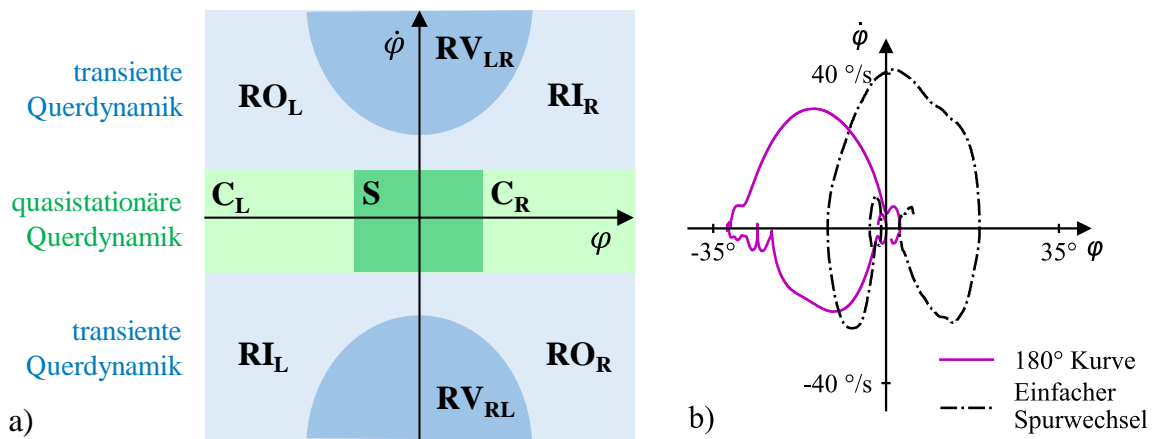


Abbildung 6.2: a) Definition querdynamischer Manöversegmente anhand der Fahrzustände Rollwinkel und -rate (S: Geradeausfahrt, C: quasistationäre Kurvenfahrt, RI: Schräglagenaufbau, RO: Schräglagenabbau, RV: Schräglagenwechsel, Indizes L/R für Richtung). b) beispielhafte Trajektorien der Rollwinkelzustände in 180°-Linkskurve und einfachem Spurwechsel nach links.

Im Bereich der transienten Querdynamik werden die MS Schräglagenaufbau (RI – „roll in“), -abbau (RO – „roll out“) und -wechsel (RV – „roll over“) unterschieden. Der Aufbau RI ist durch Vorzeichengleichheit von $\dot{\phi}$ und ϕ definiert, der Abbau RO durch entgegengesetzte Vorzeichen; entsprechend sind die Quadranten in Abbildung 6.2a gekennzeichnet. Ein Schräglagenwechsel RV liegt vor, wenn ϕ in einer durchgehend transienten Rollbewegung das Vorzeichen wechselt, also die Kurvenrichtung in einem dynamischen Manöver gewechselt wird. Bei einer bestimmten Kombination aus hohem $|\dot{\phi}|$ und niedrigem $|\phi|$ wird RV klassifiziert, wie in Form der dunkelblauen halbrunden Bereiche in Abbildung 6.2a dargestellt ist. Insgesamt ergeben sich fünf querdynamische MS. Werden zusätzlich – wie in Abbildung 6.2a durch die Indizes L und R gekennzeichnet – die Richtungen der Kurven unterschieden, sind es neun MS.

Damit die Segmentierung der Querdynamik im Kontext von Fahrmanövern sinnvoll ist, gibt es weitere Übergangsbedingungen zwischen den MS, die in der schematischen Darstellung in Abbildung 6.2a aus Gründen der Übersichtlichkeit nicht abgebildet sind. Zum einen wird ein einmal klassifizierter Schräglagenwechsel auch außerhalb des dunkelblauen Bereichs in Abbildung 6.2a so lange beibehalten, bis der Wechsel abgeschlossen ist, also ein quasistationärer Zustand erreicht ist oder direkt ein Schräglagenabbau eingeleitet wird. Zum anderen wird ein quasistationäres MS im Anschluss an ein transientes erst klassifiziert, sofern der Fahrer in diesem verweilt – und damit eine quasistationäre Fahrerabsicht vorliegt.

In Abbildung 6.3 sind abermals die zwei Beispielmanöver aus Abbildung 6.2b im Rolldynamik-Zustandsraum gezeigt, wobei jetzt die mittels optimiertem Zustandsautomat erzeugten MS farblich markiert sind. An der Segmentierung des einfachen Spurwechsels nach links können die eben beschriebenen weiteren Übergangsbedingungen nachvollzogen werden. Zum einen ist

das MS des pink markierten Schräglagenwechsels von Links- in Rechtskurve RV_{LR} erst abgeschlossen, wenn der hellgrüne Schräglagenabbau aus der Rechtskurve RO_R begonnen wird. Zum anderen durchläuft die Rolldynamiktrajektorie im einfachen Spurwechsel zwar zweimal den quasistationären Bereich, doch findet dort keine Klassifikation quasistationärer Kurvenfahrt, sondern der direkte Übergang zwischen transienten MS statt, weil der Fahrer im Spurwechsel keine Absicht hat in einem stationären Zustand der Querdynamik zu verweilen. In der Rolldynamiktrajektorie der 180°-Kurve in Abbildung 6.3 ist hingegen ein Verweilen des Motorrads bei negativen Rollwinkeln zu erkennen, weshalb hier das rot gekennzeichnete MS quasistationäre Kurvenfahrt klassifiziert wird.

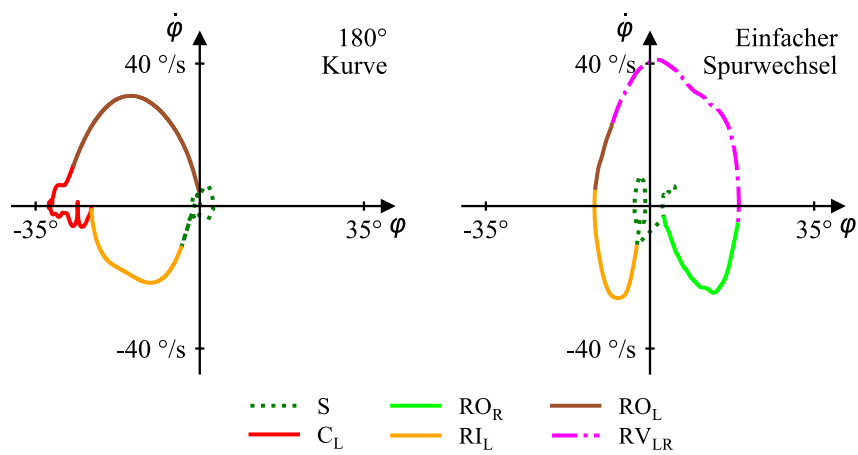


Abbildung 6.3: Klassifikation von Manöversegmenten für die Fahrmanöver 180°-Linkskurve und einfacher Spurwechsel nach links, erzeugt mittels optimiertem Zustandsautomaten.

6.2.2 Realisierung mit Zustandsautomat

Die eben beschriebene Logik der Manöversegmentierung wird in einem Zustandsautomaten umgesetzt. Dieser berücksichtigt bei der Klassifikation des aktuellen MS neben den gefilterten Fahrzuständen Rollwinkel und -rate auch die Geschwindigkeit, eine berechnete Rollbeschleunigung und einen gleitenden Durchschnitt der Rollrate. Er ist echtzeitfähig ausgelegt, d.h. es gehen keine Informationen über zukünftige Fahrzustände ein.

Der Zustandsautomat ist geschachtelt in drei Ebenen aufgebaut. Auf oberster Ebene wird in Abhängigkeit von einer Grenzgeschwindigkeit und Geschwindigkeitshysterese die Langsamfahrt, in der keine MS-Klassifikation stattfindet, von der Normalfahrt unterschieden. Die Grenzgeschwindigkeit wird entsprechend dem in Abschnitt 7.1 beschriebenen Ansatz der Trajektorienprädiktion auf 30 km/h festgelegt.

Auf der zweiten Ebene werden in Normalfahrt quasistationäre und transiente Querdynamik unterschieden. Ein Grenzwert der Rollrate unterscheidet beide Domänen und wird durch eine Hysterese ergänzt, die zu häufige Zustandsübergänge auf dieser Ebene verhindert. Ein

zusätzlicher Grenzwert der Rollbeschleunigung verhindert, dass während schneller Vorzeichenwechsel der Rollrate un plausible quasistationäre MS klassifiziert werden (siehe Beispiel des einfachen Spurwechsels in Abbildung 6.3).

Auf dritter und unterster Ebene des Zustandsautomaten sind die in Abschnitt 6.2.1 eingeführten MS definiert. In der quasistationären Domäne werden Geradeausfahrt, Links- und Rechtskurve (S , C_L & C_R) unterschieden. Dies geschieht mittels Grenzwert und Hysterese im Rollwinkel. In der transienten Domäne werden Schräglagenaufbau, -abbau und -wechsel (RI , RO & RV) in jeweils beide Richtungen unterschieden. Zwischen den sechs MS gibt es zahlreiche gerichtete Übergangsbedingungen, welche die Vorzeichen von Rollwinkel und -rate, Rollratengrenzwert und -hysterese, die Rollwinkelhysterese, den Rollbeschleunigungsgrenzwert sowie Grenzwerte für RV in Rollrate und -winkel berücksichtigen. Der Aufbau des Zustandsautomaten mit allen Übergangsbedingungen ist in Anhang A.5 beschrieben.

Insgesamt kann das Verhalten des Zustandsautomaten über neun wählbare Parameter in den Übergangsbedingungen eingestellt werden. Davon werden der Grenzwert und die Hysterese der Geschwindigkeit fest vorgegeben, weil sie für die Charakteristik der querdynamischen Segmentierung nicht entscheidend sind. Die Werte der übrigen sieben Parameter werden mittels Expertenwissen und Optimierung eingestellt. Dabei gilt es vier Anforderungen zu erfüllen:

- C und S sind sinnvoll zu unterscheiden.
- Es sollen keine unlogischen Abfolgen von MS klassifiziert werden. Z.B. sollte auf RV kein S folgen.
- Stabilisierungseingaben und kleine Kurskorrekturen des Motorradfahrers sollen nicht zur Klassifikation von transienten MS führen.
- Einzelne MS sollen plausible Längen besitzen, denn ständig wechselnde Klassifizierungen oder wenige Zehntelsekunden andauernde MS entsprechen keiner plausiblen Fahrerabsicht bzgl. eines Fahrmanövers.

Um die Anforderung (1) zu erreichen, werden für eine beispielhafte Messfahrt ausschließlich quasistationäre MS klassifiziert. In mehreren Versuchen wird der Rollwinkelgrenzwert variiert und die sich ergebende Aufteilung von S und C auf einer interaktiven Karte betrachtet. Mit einem Wert von 8° ergibt sich eine gute Einstellung, weil kaum noch falsch positive Erkennungen von Kurven auftreten. Zum Vergleich wird von Magiera [38] ein leicht niedrigerer Rollwinkelgrenzwert von 6° angewendet.

Um die Anforderungen (3) und (4) zu erreichen, wird anhand beispielhafter Fahrdaten ein erster Rollratengrenzwert zur Unterscheidung von quasistationärer und transienter Domäne ermittelt. In Abbildung 6.4a ist die mit 2 Hz Tiefpass gefilterte Trajektorie der Rolldynamik einer fünfminütigen Messfahrt dargestellt. In diesem Diagramm kann die Stabilisierungsaktivität mit

geringem $|\dot{\varphi}|$ von den bewussten transienten Rollbewegungen „mit dem Auge“ unterschieden werden. Betrachtet man in dieser Messung nur Abschnitte mit einer Zeitdauer kleiner 1 s zwischen zwei Vorzeichenwechseln in $\dot{\varphi}$, verbleiben die in Abbildung 6.4b gezeigten Datenpunkte. Sie stellen kurze Rollratenschwankungen der Stabilisierung bzw. geringfügige Kurskorrekturen beim Einstellen der Fahrtrajektorie dar und liegen innerhalb der eingezeichneten horizontalen Grenzen zwischen -10 und 10 $^{\circ}/s$. Dieser Rollratengrenzwert dient als erste Parametrierung zur Abgrenzung der transienten MS.




Abbildung 6.4: Trajektorie der Rolldynamik einer fünfminütigen Fahrt: a) gesamte Messung mit 2 Hz Tiefpass gefiltert, b) Abschnitte mit weniger als 1 s Zeitabstand zwischen Vorzeichenwechseln in der Rollrate mit markierter Rollratengrenze von $|10$ $^{\circ}/s$.

Für die Parametrierung der RV-Grenzwerte in Rollwinkel und -rate (Anforderung (2)) werden zunächst niedrige Werte gewählt, sodass zahlreiche – auch falsch positive – RV klassifiziert werden. Anschließend wird mit einer Korrekturroutine jedes auf RV folgende MS geprüft und im Fall einer falsch positiven Erkennung (z.B. S nach RV) wird der Wechsel entfernt. Auf die korrigierten MS des gesamten Datensatzes werden die RV-Grenzwerte anschließend optimiert. Zur Umsetzung von Anforderung (4) wird abermals eine Korrekturroutine eingesetzt, die jedes MS bzgl. seiner Länge und im Kontext der umliegenden MS auf Plausibilität prüft; z.B. wird ein sehr kurzes Segment C ($< 0,5$ s) zwischen zwei längeren Segmenten RI als unplausibel bzgl. einer Fahrerabsicht angesehen und deshalb entfernt. Die vollständigen Kriterien der Korrekturroutine sind in Anhang A.6 dokumentiert. Auf den korrigierten MS des gesamten Datensatzes werden alle Hysterese-Parameter, der Rollbeschleunigungs- und Rollratengrenzwert optimiert.

Der optimierte Zustandsautomat kann online für die Manöversegmentierung eingesetzt werden. Für seine Anwendung in der Datenanalyse wird jedoch der Freiraum der Offline-Auswertung in Form der phasenverzugsfreien Filterung der Messsignale und des Einsatzes der Korrekturroutine zur Entfernung unplausibler MS ausgenutzt. In Anhang A.6 ist beschrieben, wie häufig die MS-Ausgabe des optimierten Zustandsautomaten korrigiert wird, wenn alle Messfahrten der Datenerhebung ausgewertet werden. Zahlreiche Korrekturen der MS Schräglagenaufbau

und unplausibler Schräglagenaufbauten aus Geradeausfahrt für bestimmte Testfahrer machen deutlich, dass die Manöversegmentierung mit gleichbleibender Parametrierung für alle Messfahrten nur dank der Korrekturroutine sinnvoll möglich ist.

6.2.3 Charakteristik der Fahrdaten

Die Gesamtheit der erhobenen Realfahrdaten kann mithilfe der querdynamischen Manöversegmentierung charakterisiert werden. In 86 % der insgesamt 74 h Fahrzeit wurde schneller als 30 km/h gefahren. Alle folgenden Angaben beziehen sich auf diesen Anteil der Messdaten. Das Kreisdiagramm in Abbildung 6.5 zeigt die zeitlichen Anteile der richtungsabhängigen MS und charakterisiert damit die Häufigkeit von transienter und quasistationärer Kurvenfahrt.

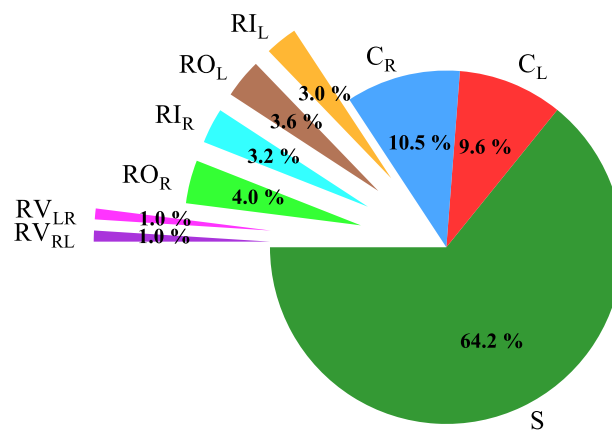


Abbildung 6.5: Zeitliche Anteile der querdynamischen Manöversegmente für Fahrt mit mehr als 30 km/h Geschwindigkeit. (S: Geradeausfahrt, C: quasistationäre Kurvenfahrt, RI: Schräglagenaufbau, RO: Schräglagenabbau, RV: Schräglagenwechsel, Indizes L/R für Kurvenrichtung)

In rund zwei Drittel der Zeit liegt Geradeausfahrt vor, weitere 20 % entfallen auf die quasistationäre Kurvenfahrt in beide Richtungen. Die transienten MS Schräglagenaufbau und -abbau sind in beide Richtungen mit Werten zwischen 3 und 4 % zu ähnlichen Anteilen vorhanden, jedoch besteht in beide Kurvenrichtungen eine Tendenz zu mehr Schräglagenabbau als -aufbau. Schräglagenwechsel sind mit je 1 % die seltensten MS. In quasistationärer Kurvenfahrt (+9 %), Schräglagenaufbau (+8 %) und -abbau (+11 %) befinden sich jeweils mehr Rechts- als Linkskurven im Datensatz (Differenz von Rechts- und Linkskurven bezogen auf die Linkskurven in Klammern).

Neben der kumulativen Häufigkeit im gesamten Datensatz wird die Länge der einzelnen MS analysiert. In den zwei Histogramm in Abbildung 6.6 sind die Verteilungen der Zeitdauern von quasistationären und transienten MS der Kurvenfahrt für beide Kurvenrichtungen kombiniert dargestellt. Quasistationäre Kurvenfahrten haben im Median eine Länge von 2,0 s, der Durchschnitt beträgt aufgrund weniger sehr langer Kurven 2,9 s. Rund ein Viertel aller

quasistationären Kurvenabschnitte sind kürzer als 1 s. Die transienten MS Schräglagenaufbau und -abbau dauern in rund 90 % der Fälle weniger als 2 s und in 50 % weniger als 1 s. Wie die grüne Verteilung in Abbildung 6.6b erkennen lässt, dauern Schräglagenwechsel vergleichsweise länger, nämlich 1,4 s im Durchschnitt. Die mittleren zwei Drittel aller Schräglagenwechsel sind zwischen 1 und 1,9 s lang.

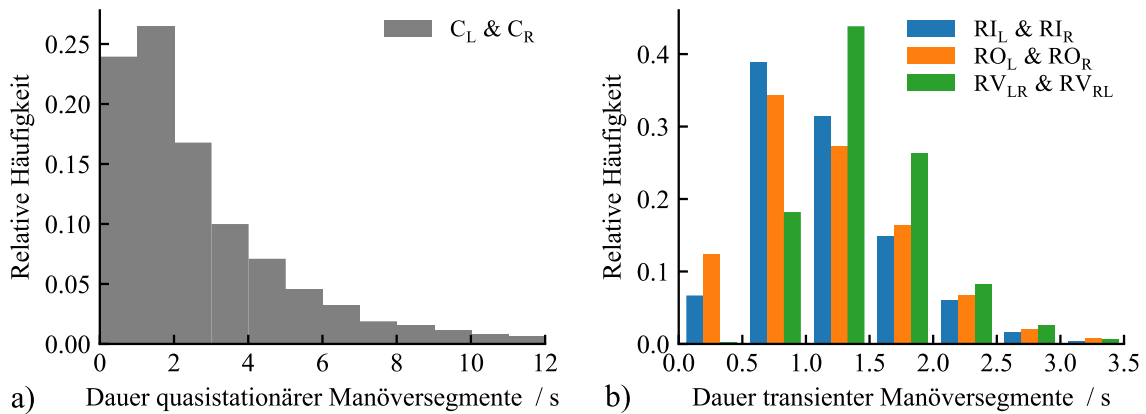


Abbildung 6.6: Histogramme über die Zeitdauern von Manöversegmenten: a) quasistationäre Kurvenfahrt, b) transiente Segmente.

Trotz einer bewusst kurvigen Streckenauswahl auf den diversen Routen der Messfahrten beinhaltet der Datensatz im überwiegenden Anteil die Geradeausfahrt. Dies wird bei der Vorbereitung der Trainingsdaten für das maschinelle Lernen der manöverbasierten Trajektorienprädiktion in Abschnitt 7.3 entsprechend berücksichtigt. Abgesehen von der Geradeausfahrt, liegt der Großteil aller querdynamischen MS für weniger als 2 s vor. Demnach werden über den 4 s langen Prädiktionshorizont des in Kapitel 7 realisierten Modells zur lateralen Trajektorienprädiktion zumeist mehrere MS vorliegen, wenn sich das Motorrad in Kurvenfahrt befindet. Dies macht die große Herausforderung einer Prädiktion der zukünftigen Rolldynamik über diesen Zeitraum deutlich.

6.3 Fahrweise und Fahrstil im Datensatz

In diesem Abschnitt werden die Fahrten der Datenerhebung einzeln hinsichtlich der Fahrweise (Beschleunigungen, Rolldynamik) und des Fahrstils (Fahrerbewegung) der Testfahrer untersucht. Aus den Auswertungen kann nicht auf die Fahrfertigkeit der Fahrer geschlossen werden, weil eine sportliche Fahrweise beispielsweise sowohl aus hoher Risikobereitschaft als auch hoher Fahrfertigkeit resultieren kann. Weiterhin besteht eine eingeschränkte Vergleichbarkeit der Fahrten aufgrund der unterschiedlichen Streckenführungen. Sie bieten unterschiedliche Charakteristiken (z.B. Kurvigkeit, Geschwindigkeitsbeschränkungen) und damit ungleiche Voraussetzungen, insbesondere für das Ausleben von Fahrweisen. Zudem

bestehen nicht beobachtbare individuelle Faktoren, wie z.B. Verkehrsaufkommen und Wetter, die einen direkten Vergleich der Fahrten stören. Anhand mehrmaliger Fahrten zweier Probanden an unterschiedlichen Tagen ergibt sich jedoch die Möglichkeit, den Einfluss von Streckenführung und Tagesform auf die Fahrweise abzuschätzen. Alle folgenden Auswertungen beziehen sich auf die Fahrt mit mehr als 30 km/h Geschwindigkeit.

Zur Analyse der Fahrweise bietet sich die statistische Betrachtung von Fahrdynamikgrößen über die Dauer einer Messfahrt an. Ein bekanntes Beispiel ist das g-g-Diagramm, in welchem die Ausnutzung von Längs- und Querschleunigung dargestellt wird. Diesem Diagramm kann die Kennzahl der abgedeckten Fläche entnommen werden, die das vom Fahrer ausgenutzte kombinierte Beschleunigungsvermögen quantifiziert. Will et al. [40] analysieren zudem die Form der abgedeckten Fläche im g-g-Diagramm und identifizieren drei charakteristische Muster des Fahrerverhaltens. Für diese Arbeit wird sich gegen die manuelle Klassifizierung der Form „mit dem Auge“ entschieden. Stattdessen wird ein Formfaktor berechnet, indem der Quotient aus der Summe der Flächenschwerpunkte in den vier Quadranten des g-g-Diagramms und den vier Extremwerten entlang der zwei Achsen gebildet wird. Dieser Formfaktor nimmt im Grenzfall eines ideal rechteckigen g-g-Diagramms den Wert Eins, für einen Kreis 0,85, für eine Raute zwei Drittel und für ein Kreuz (d.h. keine überlagerte Beschleunigung) Null an.

In Abbildung 6.7a ist der Formfaktor über der Fläche des g-g-Diagramms dargestellt; darin repräsentiert jeder Datenpunkt eine Messfahrt, wobei sich Farbe und Form entsprechend den Testfahrern unterscheiden. Zunächst fällt die stark variierende Fläche des g-g-Diagramms zwischen 70 und 207 $(\text{m/s}^2)^2$ auf, die unterschiedlich sportliche Fahrweisen in den Fahrten anzeigt. Die Fläche eines Kreises mit einem Radius von 1 g Beschleunigung beträgt zum Vergleich 302 $(\text{m/s}^2)^2$. Für mehrere Fahrten des gleichen Fahrers, z.B. die dreieckig-grünen Datenpunkte in Abbildung 6.7a, streuen Fläche und Formfaktor deutlich, was für einen großen Einfluss der Strecken- und Umgebungsbedingungen auf die beobachtete Fahrweise bzgl. des Beschleunigungsverhaltens spricht. Der Formfaktor des g-g-Diagramms ist relativ gleichmäßig zwischen 0,65 und 0,8 verteilt, die Form der g-g-Diagramme aller Fahrten liegt also zwischen Raute und Kreis.

Die g-g-Diagramme der zwei Messfahrten mit den unterschiedlichsten Formfaktoren, in Abbildung 6.7a mit „b)“ und „c)“ gekennzeichnet, sind in Abbildung 6.7b/c dargestellt, um das Ausmaß des Unterschieds aufzuzeigen. Hierin ist die Häufigkeit der Beschleunigungen farblich angezeigt. Es ist zu erkennen, dass der niedrige Formfaktor des g-g-Diagramms „c)“ besonders durch die hohen Bremsverzögerungen ($-a_x$) begünstigt wird.

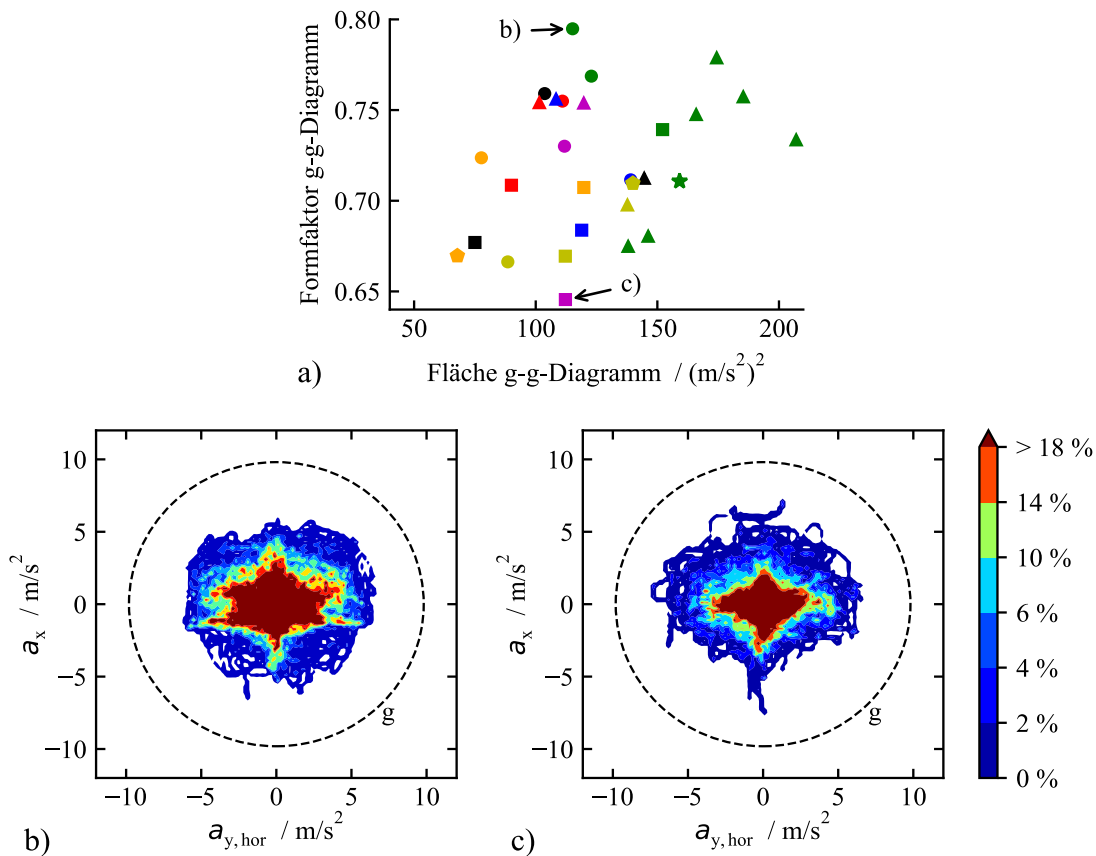


Abbildung 6.7: Formfaktor und Fläche des g-g-Diagramms für jede Messfahrt in a). Vergleich der g-g-Diagramme der Fahrer b) und c) mit stark unterschiedlichem Formfaktor.

Zur Analyse der querdynamischen Fahrweise werden die maximalen Rollwinkel und -raten betrachtet, die die Fahrer in den Messfahrten erreicht haben. Abbildung 6.8a stellt die Mittelwerte aus Links- und Rechtskurven für beide Größen dar. Mit maximalen Rollwinkeln von 33 bis 49° nutzen die Fahrer das Querdynamikpotential des Motorrads deutlich unterschiedlich aus. Die Extremwerte der Rollrate zeigen eine signifikante Korrelation mit denen des Rollwinkels.

In Abbildung 6.8b sind die Differenzen der Extremwerte aus Rechts- und Linkskurven dargestellt, um etwaige Vorzugsrichtungen der Testfahrer zu identifizieren. Die Mehrzahl der Fahrer erreicht größere Rollwinkel in Rechtskurven. Die mehrmaligen Fahrten des Fahrers mit den dreieckig-grünen Datenpunkten zeigen jedoch deutliche Schwankungen der Differenzen, sodass Streckencharakteristika als Ursache in Frage kommen. In der maximalen Rollrate streuen die Differenzen zwischen den Kurvenrichtungen mit $\pm 15\%$ deutlich mehr als im Rollwinkel und es ist weder eine Richtungstendenz noch eine Korrelation mit der Rollwinkelvorzugsrichtung zu erkennen. Hier wird die Streckencharakteristik als ausschlaggebende Ursache angesehen.

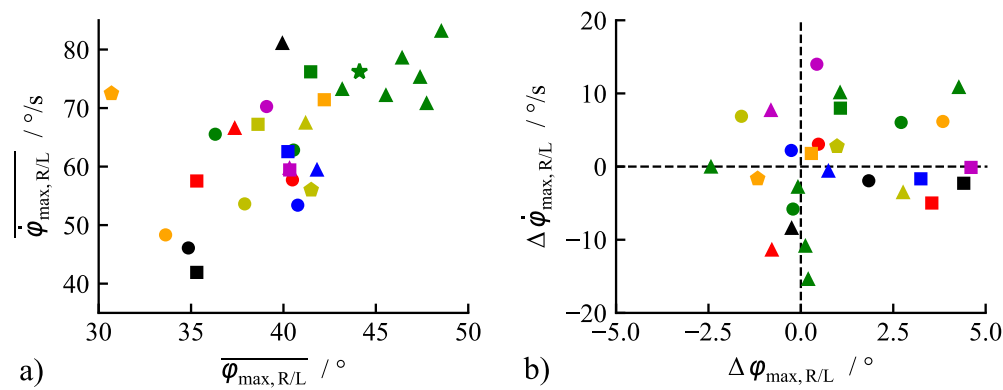


Abbildung 6.8: Maximale Rolldynamik ausgewertet für jede Messfahrt: a) Mittelwert aus Rechts- und Linkskurve, b) Unterschiede der Extremwerte zwischen Rechts- und Linkskurve.

Bei Betrachtung der Fahreroberkörperposition stechen ausgeprägte Unterschiede einzelner Messfahrten hervor. Abbildung 6.9a zeigt auf der y-Achse, dass die Fahrer in der Oberkörperneigung Spitzenwerte zwischen 7 und 21° erreichen, wobei nur in drei Fahrten ein maximaler Neigungswinkel von mehr als 16° auftritt. Die Spitzenwerte des lateralen Versatzes an Marker 5 (nahe des Sitzpunkts), dargestellt auf der x-Achse, liegen für alle bis auf zwei Fahrer zwischen $1,7$ und $7,5$ cm. Für diese kann geschlussfolgert werden, dass der Aufsitzpunkt nicht aktiv, d.h. als Ausdruck eines Fahrstils, verändert wurde; stattdessen sorgen die Oberkörperneigung und erneutes Auf- oder Umsetzen bei längerer Fahrt (z.B. nach Stillstand) für diese kleinen Änderungen des lateralen Versatzes.

Zwei Fahrer verändern ihren Sitzpunkt aktiv und erreichen Spitzenwerte im lateralen Versatz $y_{F,M5}$ von rund 11 cm. Dass sie trotzdem sehr unterschiedliche Fahrstile nutzen, wird in Abbildung 6.9b deutlich. Das Diagramm zeigt die Fläche des Fahrerbewegungsdiagramms (φ_F über $y_{F,M5}$, ausgewertet wie das g-g-Diagramm) auf der x-Achse und die Differenz der Flächen von 1. & 3. Quadranten gegenüber denen des 2. & 4. Quadranten auf der y-Achse – im exemplarischen φ_F - $y_{F,M5}$ -Diagramm in Abbildung 6.9c ist die Unterteilung in Quadranten eingezeichnet. Diese Quadranten-Differenz zeigt die Kopplung von φ_F und $y_{F,M5}$ an. Bewegt sich ein Fahrer in beiden Größen in die gleiche Richtung, überwiegen 2. & 4. Quadrant (negative Differenz). Dies tritt besonders in den Fahrstilen „Drücken“ und „Hanging-Off“ auf. Werden Neigung und Versatz des Oberkörpers in entgegengesetzte Richtungen ausgeführt, ist die Quadranten-Differenz positiv. Diese Bewegung tritt im Fahrstil „Hängen“ auf. Die zwei Fahrer mit mehr als 100 $^{\circ}\text{cm}$ Fläche in Abbildung 6.9b bewegen sich also ähnlich stark, jedoch mit unterschiedlichem Fahrstil.

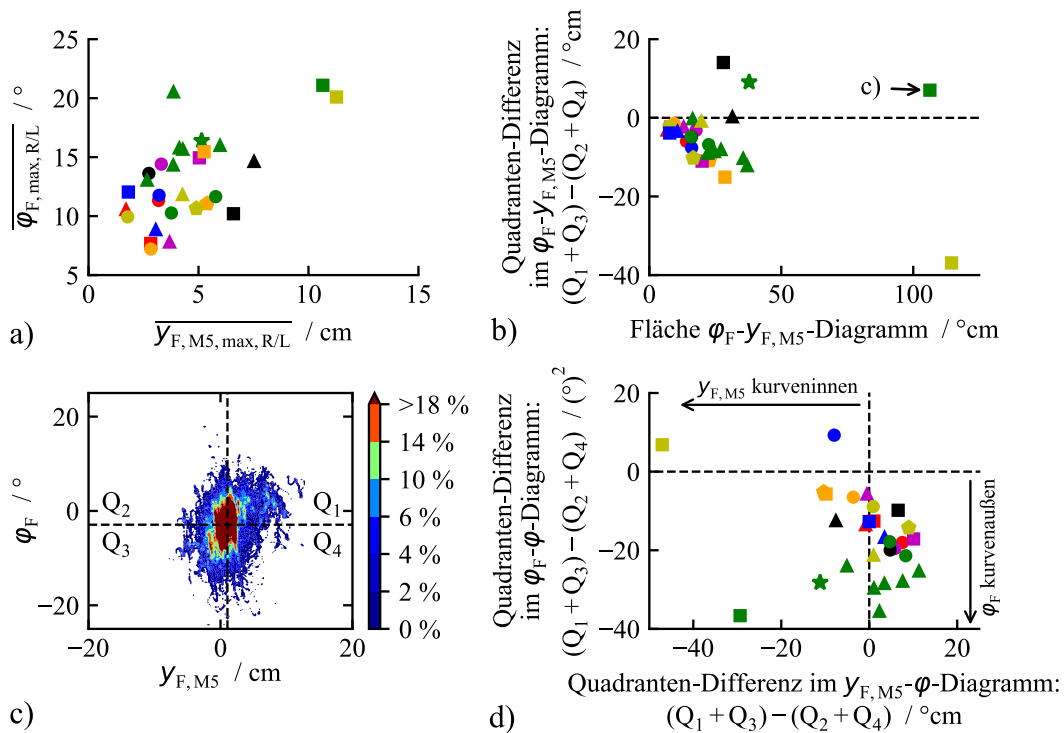


Abbildung 6.9: Fahrerbewegung ausgewertet für jede Messfahrt: a) Spitzenwerte, b) Menge und Kopplung von Oberkörperneigung und lateraler Versatz, c) exemplarisches Fahrerbewegungsdiagramm, d) Kopplung der Fahrerbewegung mit dem Rollwinkel.

Abbildung 6.9c zeigt das Fahrerbewegungsdiagramm des Fahrers mit dem quadratisch-grünen Datenpunkt. Dieser verschiebt seinen Sitzpunkt aktiv und entsprechend der Kopplung von φ_F und $y_{F, M5}$ liegt eindeutig der Fahrstil „Hängen“ vor. Um die Fahrstile der übrigen Fahrer genauer zu verstehen, wird die Korrelation zwischen Fahrerbewegung und Richtung der Kurvenfahrt, ausgedrückt durch den Rollwinkel φ , analysiert.

In Abbildung 6.9d sind die Korrelationen zwischen lateralem Versatz $y_{F, M5}$ und φ sowie zwischen Oberkörperneigung φ_F und φ auf der x- und y-Achse dargestellt. Anhand dieser wird festgestellt, ob eine Fahrerbewegung nach kurvenaußen oder -innen stattfindet. Wie schon im Fahrerbewegungsdiagramm wird dazu die Quadranten-Differenz der Signalpaarungen ausgewertet. Zum besseren Verständnis ist die Interpretation der beiden Achsen in Abbildung 6.9d mit Pfeilen angezeigt. Es wird deutlich, dass der Fahrer mit dem quadratisch-gelben Datenpunkt ganz links in Abbildung 6.9d im Fahrstil „Hanging-Off“ fährt, weil er $y_{F, M5}$ sehr deutlich und auch φ_F in Richtung kurveninnen bewegt. Die zweite deutliche Verschiebung von $y_{F, M5}$ nach kurveninnen wird vom bereits besprochenen Fahrer mit dem quadratisch-grünen Datenpunkt ausgeführt, der aber den Oberkörper gleichzeitig nach kurvenaußen lehnt („Hängen“). Alle übrigen Fahrer zeigen aufgrund des mangelnden aktiven Einsatzes von $y_{F, M5}$ erwartungsgemäß nur geringe Tendenzen bzgl. dessen Richtung. Bis auf eine Ausnahme lehnen sich alle diese Fahrer in Richtung kurvenaußen. Hierbei kann keine harte Grenze zwischen den

Fahrstilen „Lehnen“ und „Drücken“ gezogen werden. Die dreieckig-grünen Datenpunkte der mehrmaligen Fahrten eines Fahrers liegen in Abbildung 6.9b und Abbildung 6.9d beieinander, was zeigt, dass die Erfassung des Fahrstils weniger sensitiv bzgl. der Fahrtbedingungen ist.

Die Auswertungen von Beschleunigungsverhalten, Rolldynamik und Fahrerbewegung in diesem Abschnitt zeigen eine große Bandbreite an unterschiedlichen Fahrweisen und Fahrstilen der Testfahrer der Datenerhebung. Eine simple Kategorisierung der Fahrer – in z.B. sportlich und unsportlich – ist nicht möglich. Die Unterschiede begründen sich in variierender Fahrerfahrung, Risikobereitschaft, Tagesform, Witterung, Verkehr und Vorlieben. Eine solche Diversität im Datensatz ist für das Training eines maschinell gelernten Modells zur lateralen Trajektorienprädiktion in Kapitel 7 Chance und Herausforderung zugleich, weil sehr unterschiedliche Verhaltensweisen berücksichtigt bzw. über diese generalisiert werden muss. Die Ähnlichkeiten des Fahrstils für wiederholte Fahrten eines Fahrer zeigen, dass ein relevanter Datensatz nur mit mehreren Testfahrern erreicht werden kann. Glücklicherweise ist mit je einem Fahrer im „Hängen“ und „Hanging-Off“ jeder Fahrstil – wenngleich unterrepräsentiert – im Datensatz vertreten.

6.4 Korrelation von Kopfdrehung und Kurventrajektorie

Wie in Kapitel 4.4 beschrieben ist, werden die Kamera und optischen Marker der Fahrerpositionserfassung auch für die Messung des Helmdrehwinkels ψ_H eingesetzt. Ob ψ_H mit der Kurvenfahrt korreliert und damit ein potenzieller Prädiktor für die vorausliegende Querdynamik vorliegt, wird in diesem Abschnitt analysiert. Es handelt sich um die erste dem Autor bekannte Auswertung dieser Art.

Aus Untersuchungen im PKW ist bekannt, dass Fahrer in die Richtung fahren, in die sie blicken. Motorradfahrer werfen ihren Blick im Vergleich zu PKW-Fahrern jedoch auch verstärkt in den Nahbereich, um diesen auf potenzielle Gefahrenstellen zu prüfen. Dieses Verhalten ist wegen der Instabilität des Zweirads sinnvoll, macht sie aber anfällig für falsche Blicktechniken, z.B. in Form einer zu kurzen Vorausschaudistanz. Diese wird als Ursache für Fahrurfälle unter eigentlich unkritischen Umständen (z.B. keine überhöhte Geschwindigkeit) vermutet [93]. Aus Expertensicht besteht die richtige Blicktechnik in der Ausrichtung des Kopfs entsprechend der weiten Vorausschau – und damit bzgl. des Streckenverlaufs – und dem periodischen Blick in den Nahbereichs mittels Augenbewegung. Ob dies tatsächlich von den Testfahrern der Datenerhebung realisiert wurde, soll der Vergleich von ψ_H mit den gefahrenen Kurven zeigen.

6.4 Korrelation von Kopfdrehung und Kurventrajektorie

Zur Analyse werden einfache Kurven mit nur einer Richtung von Wechselkurven mit mindestens einer Richtungsänderung unterschieden. Rein transiente Manöver, wie z.B. Spurwechsel, werden nicht betrachtet. Dank der Manöversegmentierung können die Kurven einfach aus den Fahrdaten extrahiert werden. In einem Zeitraum von zwei Sekunden vor dem ersten Schräglagenaufbau bis eine Sekunde nach dem letzten Schräglagenabbau einer jeden Kurvenfahrt werden horizontierte Gierrate $\dot{\psi}_{\text{hor}}$ und Kopfdrehwinkel ψ_{H} verglichen. Die Gierrate steht stellvertretend für die gefahrene Kurventrajektorie. Der beispielhafte Verlauf beider Signale für eine „links-rechts-links“ Wechselkurve ist in Abbildung 6.10 dargestellt.




Abbildung 6.10: Verlauf von Kopfdrehwinkel und horizontierter Gierrate für eine beispielhafte Wechselkurve (gefiltert mit 2 Hz Tiefpass). Mittlerer Zeitverzug t und maximaler Korrelationsfaktor ρ (aus Kreuzkorrelation) sowie Median des Signalverhältnisses \tilde{A} sind angegeben.

Analog zur Analyse der Slalomfahrten in Abschnitt 5.2.1 wird die Kreuzkorrelationsanalyse eingesetzt, um den Zusammenhang von $\dot{\psi}_{\text{hor}}$ und ψ_{H} zu untersuchen. Die Lage des Maximums der Kreuzkorrelationsfunktion ergibt den mittleren Zeitverzug $t_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ zwischen den Signalen. In der Wechselkurve in Abbildung 6.10 eilt die Kopfdrehung der Gierrate um -0,18 s voraus. Der Betrag des maximalen Korrelationsfaktors $\rho_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ selbst liegt für normierte Signale zwischen 0 und 1. Für das Beispiel in Abbildung 6.10 liegt mit 0,98 eine sehr hohe Korrelation der Signalverläufe von $\dot{\psi}_{\text{hor}}$ und ψ_{H} vor. Sofern $\rho_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ für eine Kurve den Wert von 0,5 unterschreitet, ist keine signifikante Korrelation der Signale vorhanden. Die Auswertung der anderen beiden Kennzahlen ist dann nicht sinnvoll möglich, weshalb solche Kurven von der im Folgenden beschriebenen Auswertung ausgeschlossen werden. Der Grenzwert wurde basierend auf der manuellen Analyse von Kurven mit kleinem Korrelationsfaktor festgelegt. Grund dafür kann eine schlechte Signalqualität von ψ_{H} oder ein abgewandter Blick des Fahrers, z.B. bei Prüfung des vorrangigen Verkehrs beim Einbiegen in einen Kreisverkehr, sein.

Zuletzt wird die relative Amplitude der Kopfdrehung $\tilde{A}_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ über den Kurvenverlauf berechnet, wobei der Zeitverzug $t_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ zwischen beiden Signalen entsprechend der Gleichung (6.1) kompensiert wird. Der Median $\tilde{A}_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ ist Kennzahl dafür, wie stark der Motorradfahrer im Mittel über eine Kurve den Kopf dreht.

$$A_{\dot{\psi}_{\text{hor}},\psi_{\text{H}}} = \left| \frac{\psi_{\text{H}}(t + t_{\dot{\psi}_{\text{hor}},\psi_{\text{H}}})}{\dot{\psi}_{\text{hor}}(t)} \right| \quad (6.1)$$

Abbildung 6.11 zeigt die statistische Auswertung der Kopfdrehung über alle 76 einfachen und 72 Wechselkurven einer beispielhaften Messfahrt. In den Boxplots des Korrelationsfaktors $\rho_{\dot{\psi}_{\text{hor}},\psi_{\text{H}}}$ in Abbildung 6.11a ist sichtbar, dass die Korrelation von ψ_{H} und $\dot{\psi}_{\text{hor}}$ in Wechselkurven höher als in einfachen Kurven ist. Dies trifft auf alle Messungen zu und liegt an der im Mittel längeren Zeitdauer von Wechselkurven und an einer erhöhten Stabilität der Korrelationsanalyse aufgrund der größeren Anzahl an Signalfanken. Der Anteil signifikanter Korrelationen von Kopfdrehung und Kurvenverlauf liegt in allen Messfahrten zwischen 67 und 93 % für einfache Kurven und zwischen 90 und 100 % für Wechselkurven. Von der in Abbildung 6.11 gezeigten Messfahrt werden sechs einfache Kurven (7,9 % aller einfachen Kurven) und keine Wechselkurven von der weiteren Analyse ausgeschlossen.

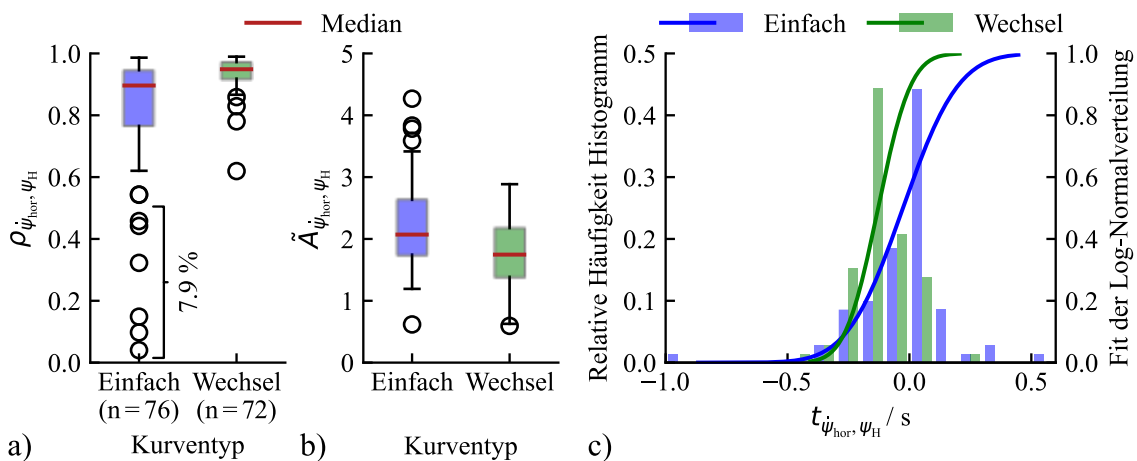


Abbildung 6.11: Statistik zur Korrelation von Kopfdrehwinkel und horisontierter Gierrate für alle einfachen Kurven und Wechselkurven einer Messfahrt. Verteilung von: a) Korrelationsfaktor ρ , b) Median der relativen Amplitude \tilde{A} und c) mittlerem Zeitverzug t .

Die Verteilungen von $\tilde{A}_{\dot{\psi}_{\text{hor}},\psi_{\text{H}}}$ für die beispielhafte Messfahrt, dargestellt in Abbildung 6.11b, zeigen eine höhere relative Amplitude der Kopfdrehung in einfachen Kurven (Median=2,1) im Vergleich zu Wechselkurven (Median=1,8). Dieser Trend bestätigt sich in allen anderen Messfahrten (siehe Abbildung 6.12a). Ursächlich dafür könnten unterschiedliche Häufigkeiten von Geschwindigkeiten und überstrichenen Kurvenwinkeln in beiden Kurventypen sein. Die Streuung von $\tilde{A}_{\dot{\psi}_{\text{hor}},\psi_{\text{H}}}$ fällt für beide Kurventypen ähnlich hoch aus.

In Abbildung 6.11c ist die Verteilung der mittleren Zeitverzüge $t_{\dot{\psi}_{\text{hor}},\psi_{\text{H}}}$ für einfache und Wechselkurven in je einem Histogramm gezeigt. Für weitere Analysen wird über jedes Histogramm eine logarithmische (Log) Normalverteilung gefittet – sie wurde gewählt, weil sie eine schiefe Verteilung abbilden kann, die für manche Fahrten vorliegt. Die resultierenden

6.4 Korrelation von Kopfdrehung und Kurventrajektorie

Verteilungsfunktionen sind auf der rechten y-Achse in Abbildung 6.11c aufgetragen und machen deutlich, dass in dieser Messfahrt die Zeitverzüge in einfachen Kurven stärker streuen als in Wechselkurven; der Interquartilsabstand – die Differenz von 75 %- und 25 %-Quantil von $t_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ – beträgt für einfache Kurven 0,31 s, für Wechselkurven nur 0,16 s. Außerdem ist die grüne gegenüber der blauen Verteilung nach links verschoben, d.h. der Fahrer dreht seinen Kopf in Wechselkurven früher als in einfachen Kurven. Für den Vergleich mehrerer Fahrten werden der Wert des 50 %-Quantils von $t_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ und der Interquartilsabstand ausgewertet.

In den drei Graphen der Abbildung 6.12 werden alle Messfahrten bzgl. der Kopfdrehung in einfachen und Wechselkurven mit signifikanter Korrelation verglichen. Im durchschnittlichen Zeitverzug zwischen $\dot{\psi}_{\text{hor}}$ und ψ_{H} (50 %-Quantil von $t_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$), dargestellt in Abbildung 6.12a, bestehen Unterschiede von bis zu 0,85 s zwischen den Fahrten. Die Unterschiede zwischen den Fahrern sind damit größer als die Streuungen des Fahrerverhaltens innerhalb einer Messung, welche durch den Interquartilsabstand in Abbildung 6.12b angegeben sind. Ein und derselbe Fahrer zeigt jedoch ähnliches Timing in einfachen Kurven und Wechselkurven, wie die Lage der Datenpunkte in Abbildung 6.12a nahe der eingezeichneten Winkelhalbierenden zeigt.

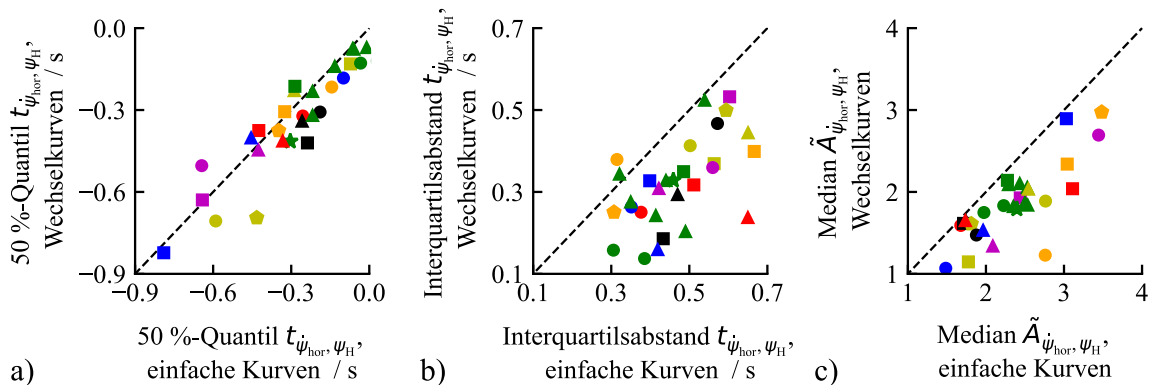


Abbildung 6.12: Vergleich von mittlerem Zeitverzug t und relativer Amplitude der Kopfdrehung \tilde{A} über alle Messfahrten in Kurven mit signifikanter Gierraten-Korrelation. Ein Datenpunkt fasst alle einfachen Kurven bzw. Wechselkurven einer Messfahrt zusammen.

Der Interquartilsabstand von $t_{\dot{\psi}_{\text{hor}}, \psi_{\text{H}}}$ ist für die überwiegende Anzahl der Messfahrten in einfachen Kurven deutlich größer als in Wechselkurven, wie die Lage der Datenpunkte rechts der Winkelhalbierenden in Abbildung 6.12b anzeigt. Demnach führen Fahrer ihre Kopfdrehung in Wechselkurven gleichmäßiger aus. Als Ursache dafür wird die anspruchsvollere Fahraufgabe beim Durchfahren von Wechselkurven gesehen. Es bestehen deutliche Unterschiede in der Höhe des Interquartilsabstands zwischen den Fahrten (0,16 bis 0,66 s). Eine Korrelation des Interquartilsabstands mit dem durchschnittlichen Zeitverzug oder der relativen Amplitude der Kopfdrehung ist nicht vorhanden.

Von den mittleren Werten der relativen Amplituden der Kopfdrehung $\tilde{A}_{\psi_{\text{hor}},\psi_{\text{H}}}$ in einfachen Kurven und Wechselkurven wird jeweils der Median für eine Messfahrt ermittelt. Im Vergleich der Kurventypen in Abbildung 6.12c liegen alle Datenpunkte rechts der Winkelhalbierenden, die Fahrer drehen ihren Kopf demnach in einfachen Kurven stärker als in Wechselkurven. Wie schon beim Timing der Kopfdrehung zeigen die Fahrer auch in der Bewegungsamplitude große Unterschiede. Der Median von $\tilde{A}_{\psi_{\text{hor}},\psi_{\text{H}}}$ reicht in einfachen Kurven von 1,5 bis 3,4 und in Wechselkurven von 1,1 bis 2,9. Dabei ist für einfache Kurven eine negative Korrelation zwischen relativer Amplitude und mittlerem Zeitverzug der Kopfdrehung vorhanden, d.h. mit stärkerem Vorseilen der Kopfbewegung gegenüber der Gierrate nimmt auch die relative Amplitude zu. Für Wechselkurven ist dieser Zusammenhang nicht signifikant.

Die dreieckig-grünen Datenpunkte der wiederholten Fahrten eines Fahrers liegen in Abbildung 6.12a und Abbildung 6.12c nah beieinander, weshalb die Einflüsse unterschiedlicher Streckencharakteristik oder sonstigen Umweltbedingungen auf die Analyse von Timing und Amplitude der Kopfbewegung als niedrig eingeschätzt werden.

Zusammengefasst ist für die überwiegende Zahl aller Kurvenfahrten in Realfahrt eine signifikante Korrelation zwischen Fahrtrajektorie und Kopfdrehung des Motorradfahrers vorhanden. Es bestehen erhebliche Unterschiede in Amplitude und Timing der Kopfbewegung zwischen den Fahrern, was auf unterschiedliche Blickstrategien im Hinblick auf die Nutzung von Kopf- und Augenbewegung (Amplitude) und die Vorausschaudistanz (Timing) schließen lässt. Für Motorradfahrer, deren Kopfdrehung der Fahrtrajektorie zeitlich deutlich vorseilt, enthält das Signal des Kopfdrehwinkels explizite Information zur Fahrerabsicht, d.h. in ψ_{H} besteht ein bedeutsamer Prädiktor für die Fahrtrajektorie in Kurvenfahrt. Jedoch gibt es auch Fahrer, die den Kopf im Mittel zeitgleich mit der Gierrate des Motorrads drehen. Für sie wird ein geringerer oder kein positiver Effekt erwartet, wenn ψ_{H} in die Trajektorienprädiktion einfließt.

Für detailliertere Auswertungen der Kopfdrehung sollte hinsichtlich weiterer Kurvenparameter – wie z.B. Kurvenwinkel, Geschwindigkeit oder Radius – oder der einzelnen Abschnitte der Kurvenfahrt unterschieden werden. Letzteres ist insbesondere für Wechselkurven interessant, weil in der durchgeführten Auswertung über mehrere Richtungswechsel gemittelt wird.

7 Manöverbasierte laterale Trajektorienprädiktion

Im Folgenden ist die Realisierung einer manöverbasierten lateralen Trajektorienprädiktion des Motorrads in Gestalt eines RNN-basierten Prädiktionsmodells beschrieben. Abschnitt 7.1 diskutiert den motorradspezifischen Modellansatz und die Rahmenbedingungen der Prädiktion. Im Anschluss werden in Abschnitt 7.2 die zur Bewertung der Modellgüte herangezogenen Metriken eingeführt. Die ausgewählte NN-Architektur und die dafür notwendige Datenaufbereitung sind in Abschnitt 7.3 beschrieben. Weiterhin werden das Vorgehen bei der Optimierung des Prädiktionsmodells und die finale Modellarchitektur in Abschnitt 7.4 vorgestellt. Zuletzt ist in Abschnitt 7.5 die Wahl eines einfachen Bewegungsmodells erläutert, das zur Einordnung der Prädiktionsgüte in Kapitel 8 herangezogen wird.

7.1 Ansatz

Entsprechend der in Abschnitt 1.4 formulierten Zielstellung der Arbeit sollen die neuartigen Messgrößen der Zustandsgrößen der Lenkung, der Lenkmoment-Fahrereingabe und des Fahrerhaltens in Oberkörperbewegung und Kopfdrehung gewinnbringend für die laterale Trajektorienprädiktion des Motorrads eingesetzt werden. Die Untersuchung des querdynamischen Übertragungsverhaltens in Kapitels 5 hat gezeigt, dass für eine physikalische Trajektorienprädiktion nur ein kleiner positiver Effekt durch die neuartigen Messgrößen erwartet werden kann. In deren Zeitverläufen werden jedoch Muster vermutet, die Informationen über die Fahrerabsicht bzgl. der vorausliegenden Kurvenfahrt darstellen. Diese sollen in einem manöverbasierten Modellansatz (siehe Abschnitt 2.2) ausgenutzt werden. Für dessen Entwicklung wird der in Kapitel 6 beschriebene Datensatz zum Realfahrverhalten von Motorradfahrern eingesetzt.

Aus zwei Gründen wird sich gegen die Nutzung von Umgebungsinformation, z.B. in Form des Straßenverlaufs aus hochauflösenden Karten, im Prädiktionsmodell entschieden. Zum einen ist deren Verfügbarkeit besonders im ländlichen Raum auf Landstraßen – wo ein Unfallschwerpunkt von Motorrad-Alleinunfällen liegt – eingeschränkt und auch in Zukunft nicht absehbar. Zum anderen besteht ein Konflikt aus angestrebter Funktion und verfügbaren Trainingsdaten. So soll das Prädiktionsmodell auch ein Abkommen von der Straße vorhersagen können (z.B. aufgrund von Schräglagenangst, siehe Anhang A.1), einer Situation, die in der Datenerhebung nicht aufgetreten und damit nicht im Datensatz vorhanden ist. Für ein mit Information über den

Straßenverlauf trainiertes Modell besteht dann die Gefahr, dass es ein Verlassen der Straße nie vorhersagen würde.

Eine interaktionsbasierte Trajektorienprädiktion wird nicht durchgeführt, weil die Aufnahme der Positionen umgebender Fahrzeuge mit entsprechender Sensorik am Versuchsmotorrad nicht im Umfang des Forschungsprojekts vorgesehen ist. Zudem wird den Interaktionen mit anderen Verkehrsteilnehmern auf der Landstraße eine deutlich geringere Relevanz zugesprochen als im Stadtverkehr.

Für die Verarbeitung der Zeitreihendaten und die Interpretation darin enthaltener Muster wird – wie im Stand der Forschung für manöverbasierte Prädiktionsmodelle üblich – ein auf RNN-Zellen basierendes NN eingesetzt; die Funktionsweise von RNN ist in Abschnitt 3.2 beschrieben. Das NN-Prädiktionsmodell soll sich auf die laterale Komponente der zukünftigen Fahrtrajektorie fokussieren, um den Effekt des manöverbasierten Ansatzes und der neuartigen Messgrößen gezielt untersuchen zu können. Es wird deshalb der Rollwinkel als Zielgröße des NN-Prädiktionsmodells definiert. Dieser stellt eine charakteristische Zustandsgröße der Querdynamik für Motorräder dar. Während die isolierte Betrachtung der Querdynamik für die Beantwortung der Forschungsfragen vorteilhaft ist, benötigen aktive Sicherheitssysteme die Information der zukünftigen Position. Deshalb wird dem NN-Prädiktionsmodell eine Transformation der Rollwinkeltrajektorien in relative Positionstrajektorien nachgeschaltet; sie ist im nachfolgenden Abschnitt 7.2 erläutert.

Die Länge des betrachteten Prädiktionshorizonts wird auf den konstanten Wert von 4 s festgelegt. Dieser Wert ist deutlich höher als die Vorausschauzeit, die physikalische Modelle des Stands der Technik mit akzeptabler Abweichung realisieren können – z.B. zeigt die simulative Untersuchung des CMC [22], dass mit dem Fortschreiben der aktuellen Krümmung eine Vorausschauzeit von nur 1 bis 2 s in Kurvenfahrt erreicht wird. Gleichzeitig ist der Wert nicht unerreichbar hoch gewählt. Für eine auf Messgrößen der Fahrereingaben, Fahrdynamik und des Fahrerverhaltens basierende Prädiktion wird nicht erwartet, dass die Vorausschauzeit größer als die Dauer eines zusammenhängenden querdynamischen Fahrmanövers ist. Es wird deshalb ein kürzerer Prädiktionshorizont als die 6 s der meisten Veröffentlichungen des autonomen Fahrens gewählt, denn jene Modelle beziehen zumeist Umgebungsinformationen mit ein, welche die erreichbare Vorausschauzeit tendenziell erhöhen (siehe Abschnitt 2.2).

Die Vorhersage der Rollwinkeltrajektorie durch das NN-Modell wird durch die Regression einer festen Anzahl von Datenpunkten entlang des 4 s langen Prädiktionshorizonts realisiert. Alternativ wäre auch die Regression von Parametern einer mathematischen Funktion denkbar, die dann zeitkontinuierlich über dem Prädiktionshorizont ausgewertet werden kann. Mit der Funktionsdefinition würde jedoch die Gestalt möglicher Rollwinkeltrajektorien a priori

eingeschränkt und somit die Fähigkeit eines NN als universeller Funktionsapproximator nicht ausgenutzt werden [76]. Der Prädiktionshorizont wird mit einem konstanten Abstand von 0,2 s diskretisiert; eine 4 s lange Rollwinkeltrajektorie besteht dementsprechend aus 20 Werten. Diese zeitliche Auflösung ist ausreichend hoch, weil selbst in hochdynamischen transienten Manövern auf Bahnführungsebene keine Rolldynamik größer 1 Hz auftritt.

Es werden nur Fahrsituationen mit mehr als 30 km/h Geschwindigkeit und damit im stabilen Bereich der Kippdynamik des Motorrads betrachtet, weil sich das querdynamische Übertragungsverhalten bei niedrigeren Geschwindigkeiten drastisch ändert – wie in Kapitel 5 gezeigt wurde. Aus der MAIDS-Unfallstudie ist ersichtlich, dass 85 % aller Motorradunfälle bei Geschwindigkeiten oberhalb von 30 km/h stattfinden [10].

7.2 Metriken

Zur Bewertung der Güte der lateralen Trajektorienprädiktion werden Metriken benötigt. Zum einen kommt eine differenzierbare Kostenfunktion für das Training des NN-Modells zur Rollwinkelprädiktion zum Einsatz. Zum anderen werden mehrere Metriken mit hohem Anschauungswert für die Analyse des Verhaltens der lateralen Trajektorienprädiktion im Modelltest angewendet.

Im Trainingsprozess des NN-Modells wird die gängige Kostenfunktion des mittleren Fehlerquadrats (MSE) verwendet, die in Abschnitt 3.2.3 in Formel (3.4) eingeführt wurde. In den $MSE(\vec{\varphi}_k, \vec{\varphi}_k^*)$ fließen alle Punkte entlang des Prädiktionshorizonts ein, weshalb Prädiktion $\vec{\varphi}_k$ und erwarteter Verlauf (GT, engl. ground truth) $\vec{\varphi}_k^*$ des Rollwinkels der k-ten Trainingsiteration als Vektoren geschrieben sind.

Im Modelltest wird die Wurzel des MSE aller Testsamples auch für jeden diskreten Zeitpunkt i auf dem Prädiktionshorizont einzeln betrachtet ($RMSE_i(\varphi_i, \varphi_i^*)$). Dadurch kann analysiert werden, wie sich der Fehler über dem Prädiktionshorizont entwickelt. Zur Verdeutlichung sind in Abbildung 7.1a die unterschiedlichen $RMSE_i(\varphi_i, \varphi_i^*)$ -Verläufe zweier exemplarischer Modelle dargestellt, die entsprechend des $MSE(\vec{\varphi}, \vec{\varphi}^*)$ gleiche Prädiktionsgüte aufweisen. Erst in diesen Verläufen über dem Prädiktionshorizont zeigt sich, dass die quadratisch-blaue Prädiktion für Vorausschauzeiten kleiner 3 s den geringeren Fehler aufweist.

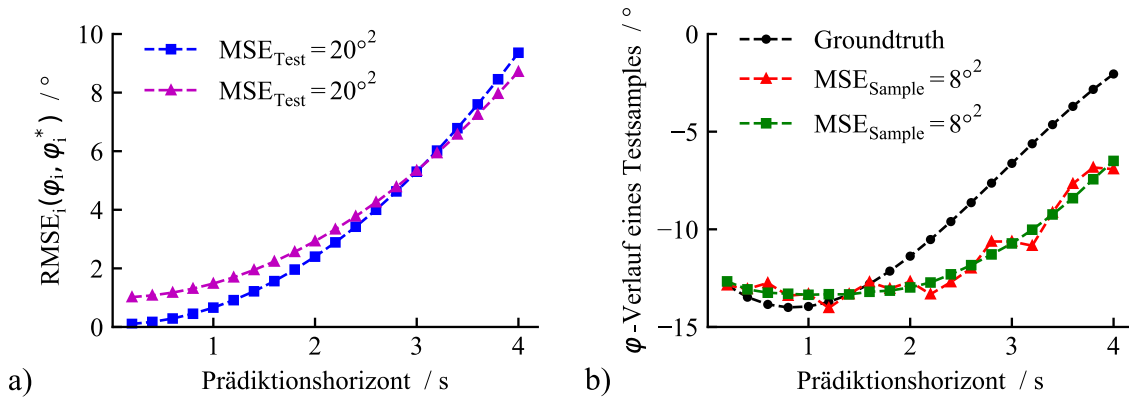


Abbildung 7.1: Beispielhafter Modelltest anhand von: a) Rollwinkel-RMSE aller Testsamples über dem Prädiktionshorizont, b) Rollwinkelprädiktionen an einem einzelnen Testsample.

Ergänzend zur Auswertung von Metriken ist auch die Betrachtung von Prädiktionen an einzelnen Testsamples ein wichtiger Bestandteil des Modelltests. Abbildung 7.1b zeigt zwei exemplarische Rollwinkelprädiktionen mit identischem MSE in einem Testsample. Am konkreten Beispiel kann festgestellt werden, dass die Prädiktion in quadratisch-grünen Markern einen wesentlich glatteren Verlauf als die in dreieckig-roten Markern aufweist. Es werden außerdem Animationen zusammenhängender Testsamples betrachtet, um das Verhalten des Modells in einem Fahrmanöver zu interpretieren.

Im Modelltest soll die Güte des Prädiktionsmodells auch auf Positionsebene bewertet werden. Deshalb wird eine Umrechnung der Rollwinkelprädiktion in relative Positionen im horizontalen Fahrzeug-KS (siehe Abschnitt 3.1.1) realisiert. Für diese muss eine Annahme bzgl. des längsdynamischen Verhaltens des Motorrads über dem Prädiktionshorizont getroffen werden. Wie in der Untersuchung des CMC [22], wird die konstante Fortschreibung der aktuellen Geschwindigkeit angenommen. Die Auswirkung dieser Annahme wird in Abschnitt 8.5 untersucht.

Im ersten Schritt der Umrechnung wird für jeden Punkt entlang des Prädiktionshorizonts eine Pfadkrümmung κ entsprechend der Formeln (7.1) berechnet. Dazu wird der Zusammenhang von Querbeschleunigung und Schräglage des Motorrads in stationärer Kurvenfahrt genutzt.

$$\kappa = \frac{-9,81 \tan(\varphi_c)}{v_x^2}$$

$$\varphi_c = \arccos\left(\frac{h_{CG}^2 - 2 h_{CG} R_t - e^2}{-2 R_t e}\right) \cdot \text{sgn}(\varphi) \quad (7.1)$$

$$e = \sqrt{(h_{CG} - R_t)^2 + 2(h_{CG} - R_t)R_t \cos(\varphi) + R_t^2}$$

Wie die Skizze in Abbildung 7.2a zeigt, ist die bzgl. der Querbeschleunigung wirksame Schräglage φ_c , die sich aus Lage des Schwerpunkts (CG) und des Reifenaufstandspunkts (CP)

ergibt, in Kurvenfahrt ungleich dem Rollwinkel des Motorrads φ , weil Motorradreifen eine gewisse Breite besitzen. Diesem Effekt wird mit dem in Abbildung 7.2a skizzierten geometrischen Modell Rechnung getragen, welches einen mittleren Reifenquerschnitt R_t und die Schwerpunkthöhe h_{CG} von Motorrad und Fahrer berücksichtigt.

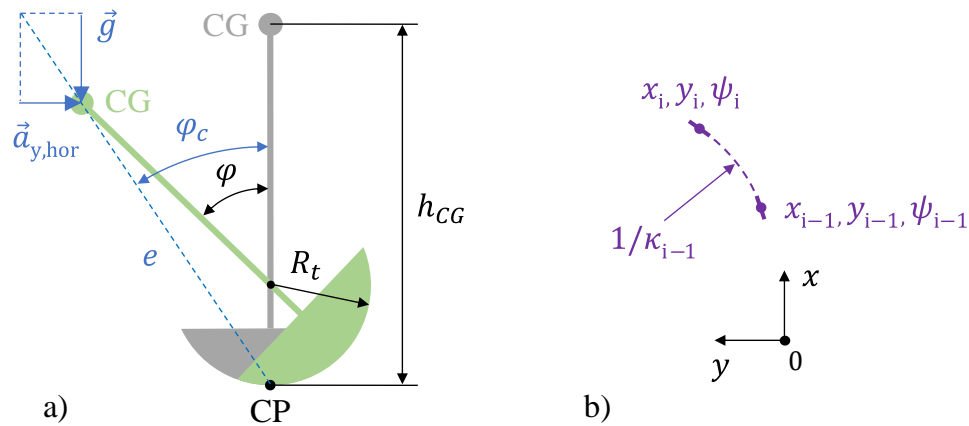


Abbildung 7.2: Umrechnung der Rollwinkel in relative Positionen. a) Herleitung des physikalisch wirksamen Rollwinkels φ_c . b) Fortschreiben der Position zwischen diskreten Prädiktionspunkten.

Die so durchgeführte Umrechnung in Pfadkrümmungen unterliegt Fehlern, weil zum einen weitere vorhandene Einflüsse auf φ_c aus Lenkwinkel, lateraler Verschiebung des Fahrerswerpunkts, Straßenneigung und Seitenwind vernachlässigt werden; die letzteren Zwei könnten mangels Beobachtbarkeit auch nicht in einem komplexeren Modell berücksichtigt werden. Zum anderen sind mit der Annahme eines stationären Kräftegleichgewichts keine Zeitverzögerungen in transienten querdynamischen Manövern abgebildet. Die absoluten Fehler aufgrund der vereinfachenden Annahmen sind für die Analyse der Modellgüte auf Positionsebene jedoch nicht hinderlich, weil auch die GT der zukünftigen Position über die gleiche Umrechnung aus der GT von Rollwinkel und Geschwindigkeit ermittelt wird. Die gemessenen GNSS-Positionen des Motorrads werden bewusst nicht als GT verwendet, weil ihre Genauigkeit aufgrund schwankender GNSS-Qualität variiert. An Streckenabschnitten mit schlechter GNSS-Qualität könnte dann keine sinnvolle Aussage über die Prädiktionsgüte auf Positionsebene getroffen werden. Scherer & Basten [41] verwenden in ihren Untersuchungen GNSS-Positionen als GT (gute Qualität auf abgeschlossener Teststrecke) und diskutieren deshalb ausführlich die Kompensation der beschriebenen Fehler bei der Umrechnung von Rollwinkel- und Geschwindigkeitstrajektorien in Positionen.

Entsprechend Formel (7.2) werden in einem zweiten Schritt die Gierwinkel des Motorrads relativ zur aktuellen Position ψ_i aus den berechneten Pfadkrümmungen κ_i und den angenommenen Längsgeschwindigkeiten $v_{x,i}$ entlang des Prädiktionshorizonts ermittelt.

$$\psi_i = \psi_{i-1} + \Delta t_i v_{x_{i-1}} \kappa_{i-1} \quad (7.2)$$

Unter der Annahme eines Pfads von konstanter Krümmung zwischen zwei diskreten Prädiktionpunkten werden im letzten Schritt die relativen Längs- und Querpositionen (x_i, y_i) nach den Gleichungen (7.3) rekursiv aus ψ_i und κ_i berechnet.

$$\begin{aligned} x_i &= x_{i-1} + \frac{\sin(\psi_i) - \sin(\psi_{i-1})}{\kappa_{i-1}} \\ y_i &= y_{i-1} - \frac{\cos(\psi_i) - \cos(\psi_{i-1})}{\kappa_{i-1}} \end{aligned} \quad (7.3)$$

Analog zum Rollwinkel wird die RMSE-Metrik auch für die relativen Positionen ausgewertet. Um die laterale und longitudinale Komponente der Trajektorienprädiktion dabei bestmöglich zu trennen, wird nicht der euklidische Abstand d zwischen GT und Prädiktion betrachtet, sondern dessen Komponenten in Längsrichtung d_{Lon} und Querrichtung d_{Lat} bzgl. der GT-Positionstrajektorie. Diese werden entsprechend der Gleichungen (7.4) für jeden Punkt des Prädiktionshorizonts berechnet.

$$\begin{aligned} d &= \sqrt{(x - x^*)^2 + (y - y^*)^2} \\ d_{\text{Lon}} &= \cos\left(\arctan\left(\frac{y - y^*}{x - x^*}\right) - \psi\right) d \operatorname{sgn}(x - x^*) \\ d_{\text{Lat}} &= \sin\left(\arctan\left(\frac{y - y^*}{x - x^*}\right) - \psi\right) d \operatorname{sgn}(x - x^*) \end{aligned} \quad (7.4)$$

Eine weitere Metrik, welche ausgehend von d_{Lat} bestimmt wird, ist der Evaluationsindex (EI), der vom CMC vorgeschlagen wird und sich aus der Anwendung der Trajektorienprädiktion in einem Kollisionswarnsystem motiviert [22]. Der EI beschreibt für jede Prädiktion die Vorausschauzeit, die der laterale Positionsfehler d_{Lat} unterhalb eines Genauigkeits-Grenzwerts bleibt. Dieser Grenzwert wird auf 2 m festgelegt, weil dies der durchschnittlichen Breite eines PKW entspricht und somit eine Kollisionswahrscheinlichkeit besteht [22].

Über den gesamten Testdatensatz kann die Verteilung des EI betrachtet werden, aus welcher ein Mittelwert oder die Lage der Quantile als Gesamt-EI-Metrik herangezogen werden kann. Ein besonderes anschauliches Maß der Prädiktionsgüte ist die Anzahl an Testsamples mit einem EI kleiner als 2 s ($n(\text{EI} < 2 \text{ s})$), weil diese beschreibt, in wie vielen Situationen eine besonders schlechte Trajektorienprädiktion vorliegt.

Die eben beschriebenen Metriken des Modelltests sind in Abbildung 7.3 beispielhaft für ein Testsample ausgewertet und grafisch dargestellt; dabei entsprechen die RMSE-Fehler des

Rollwinkels und lateralen Positionsfehlers für eine einzige Testsituation dem Fehlerbetrag. Die GT des Rollwinkels und der relativen Positionstrajektorie sind als runde schwarze Datenpunkte gezeigt. In der gezeigten Situation ist d_{Lat} bis einschließlich 3,6 s Vorausschauzeit kleiner als 2 m, weshalb dieser Wert als EI in Abbildung 7.3b eingezeichnet ist.

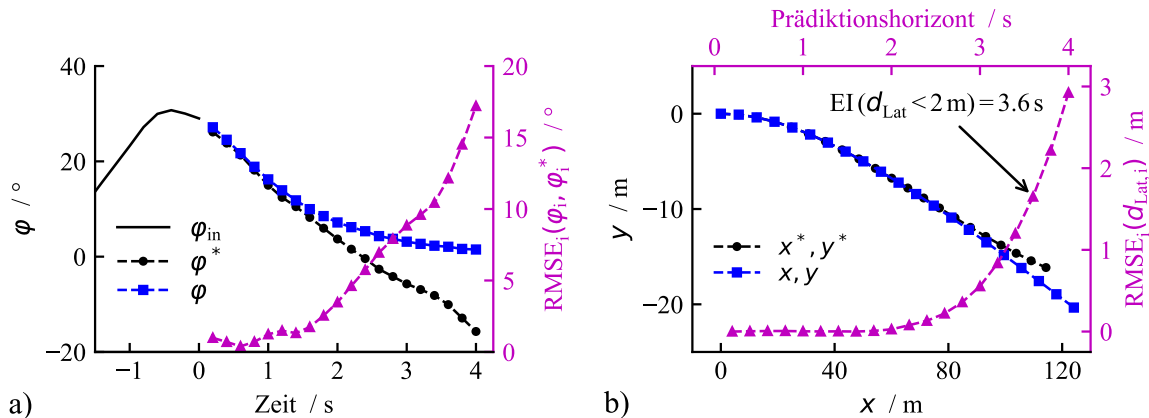


Abbildung 7.3: Metriken ausgewertet für ein Testsample: a) Rollwinkelprädiktion und RMSE-Fehler, b) errechnete relative Positionen, RMSE des lateralen Positionsfehlers d_{Lat} und Evaluationsindex (EI).

7.3 Modellarchitektur & Datenaufbereitung

Wie in der Beschreibung des Modellansatzes in Abschnitt 7.1 erläutert ist, wird ein RNN-basiertes Prädiktionsmodell entwickelt, das die zukünftigen Rollwinkel in Form von 20 diskreten Werten entlang eines 4 s langen Prädiktionshorizonts berechnet. Dieses Modell nutzt Messgrößen der Fahrdynamikzustände, der Lenkmomenteingabe und des Fahrerverhaltens. Es wird eine unimodale Prädiktion realisiert, d.h. das NN errechnet je Zeitschritt eine einzige Trajektorie. Das Fahren im Straßenverkehr ist an sich multimodaler Natur, weil zu einem gegebenen Fahrzustand mehrere mögliche zukünftige Handlungen existieren, die durch den vorausliegenden Straßenverlauf konditioniert werden. Jedoch liegt im gegebenen Ansatz kein Prädiktor für die Auswahl aus multiplen Vorhersagen vor, wie er in einem multimodalen Prädiktionsmodell benötigt wird. Der Nachteil, dass ein unimodales Modell durchschnittliches Verhalten bzgl. der Eingangsgrößen prädiziert, wird daher in Kauf genommen.

In Anlehnung an die Prädiktionsmodelle aus dem Stand der Forschung in Abschnitt 2.2 wird ein NN aus LSTM-Schichten – dem gängigsten Zelltyp von RNN – und vollvernetzten NN-Schichten realisiert, dessen parametrischer Aufbau im Folgenden beschrieben ist.

Für die Interpretation der eingehenden Zeitreihendaten werden n_{LSTM} LSTM-Schichten am Modelleingang eingesetzt, die einen konzentrierten Vektor ohne Zeitdimension zum Ausgang haben. Dieser wird anschließend in n_{MLP} sequenziellen und voll vernetzten NN-Schichten, dem sogenannten mehrlagigen Perzeptron (MLP), weiterverarbeitet. Im MLP wird eine Dropout-Regularisierung mit der Wahrscheinlichkeit p_{Do} nach der ersten NN-Schicht vorgesehen, um

einer Überanpassung im Modelltraining vorzubeugen. Zuletzt berechnet die Ausgabeschicht des NN entsprechend der Anzahl der Prädiktionspunkte in 20 Neuronen die Ausgabe des NN-Modells.

Hyperparameter der NN-Modellarchitektur	Wert / [Wertebereich] / {Zwangsbedingung}
Anzahl Prädiktionspunkte, n_p	20
Diskretisierung der Prädiktionspunkte, T_p / s	0,2
Anzahl Eingangsgrößen, n_F	16
Diskretisierung der Eingangsdaten, T_{in} / s	[0,02; 0,05; 0,1; 0,2]
Länge der Eingangszeitreihe (Anzahl Punkte), n_{in}	[10 i + 1, $i = 1 \dots 10, i \in \mathbb{N}$]
Anzahl LSTM-Schichten, n_{LSTM}	[1; 2]
Zellanzahl je LSTM-Schicht, h_{LSTM}	[32; 64; 96; 128; 160; 192; 224; 256]
Anzahl Schichten im MLP, n_{MLP}	[1; 2]
Zellanzahl der j-ten NN-Schicht im MLP, $h_{MLP,j}$	{ $h_{LSTM}/j, j = 1 \dots n_{MLP}, j \in \mathbb{N}$ }
Dropout-Regularisierung nach 1. MLP-Schicht, p_{Do}	0,2
Aktivierungsfunktion in LSTM-Schichten	tanh
Aktivierungsfunktion in MLP-& Ausgangsschicht	ReLU (engl. Rectified Linear Unit)

Tabelle 7.1: Hyperparameter der NN-Architektur und deren Einstellung, Wertebereich oder Zwangsbedingung.

Die beschriebene Modellarchitektur bietet eine sehr hohe Anzahl möglicher Konfigurationen, was die Optimierung der Modellparameter (HP, für engl. Hyperparameter) komplex macht. Es werden deshalb die in Tabelle 7.1 aufgeführten Werte, Wertebereiche und Zwangsbedingungen für die HP definiert, welche die Anzahl möglicher Modellarchitekturen auf sinnvolle Kombinationen reduziert. Als Anhaltswerte für die Wahl der HP werden die in der Literatur beschriebenen Modelle herangezogen.

Hyperparameter des Modelltrainings	Wert / [Wertebereich]
Batch-Größe, n_B	[$2^i, i = 5 \dots 14, i \in \mathbb{N}$]
Lernrate, α_L	[$10^{-5} \dots 10^{-2}$]
Anzahl Trainingsepochen, n_E	50
Optimierungsalgorithmus	Adam

Tabelle 7.2: Hyperparameter (HP) des NN-Trainings und deren Wert oder Wertebereich.

Neben den HP der Modellarchitektur werden vier weitere HP des Modelltrainings entsprechend der in Tabelle 7.2 gezeigten Werte und Wertebereiche definiert. Es kommt der weit verbreitete Adam-Optimierungsalgorithmus zum Einsatz. Für die Anzahl der Trainingsepochen n_E wird

ein fester Wert gewählt, weil dieser hauptsächlich von der Größe des Trainingsdatensatzes abhängt. Die Batchgröße n_B wird im Bereich von 32 bis 2^{14} variiert, wobei große Werte ein schnelles Training ermöglichen, wenn – wie in dieser Arbeit – auf leistungsfähigen Grafikkarten trainiert wird. Mit der Variation von n_B wird auch die Lernrate α_L als variabler Parameter definiert.

Die durch die HP definierte parametrische Modellarchitektur ist in Abbildung 7.4 in einem Signalfussplan skizziert. Darin sind die einzelnen Schichten des Modells als Quadrate dargestellt. In eckigen Klammern ist die Dimensionalität des Datenflusses zwischen den einzelnen Modellteilen während des Trainings mit Batchgröße n_B angegeben.

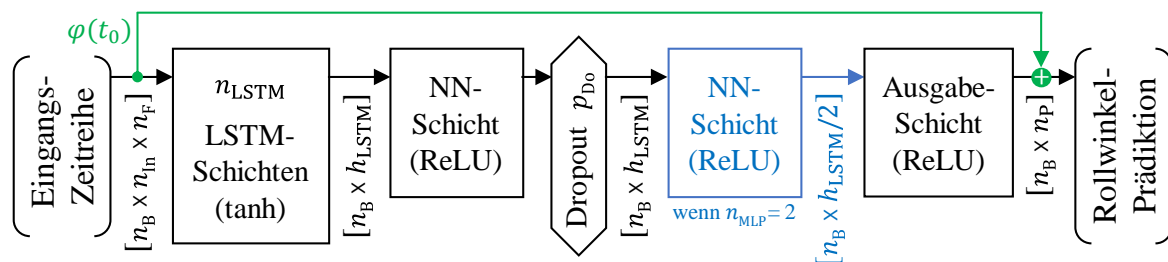


Abbildung 7.4: Parametrische Architektur und Dimensionalität des Datenflusses im Rollwinkelprädiktionsmodell.

Wie in Abbildung 7.4 grün hervorgehoben ist, besitzt das Prädiktionsmodell eine direkte Verbindung zwischen Eingang und Ausgang, indem der Rollwinkel zum aktuellen Zeitpunkt $\varphi(t_0)$ aus der Eingangszeitreihe auf die Prädiktion des NN addiert wird. Das NN berechnet somit keine absoluten Rollwinkel, sondern eine Differenztrajektorie bzgl. $\varphi(t_0)$. Dieser Ansatz, der von Alché & La Fortelle [53] bei der Prädiktion von Position und Geschwindigkeit von PKW eingesetzt wird, begünstigt glattere Verläufe der Prädiktionen, insbesondere in den ersten, nahen Punkten auf dem Prädiktionshorizont.

Für Training, Validierung und Test des Prädiktionsmodells müssen die Fahrdaten aus Kapitel 6 entsprechend der oberen fünf HP aus Tabelle 7.1 in speziell formatierte Ein- und Ausgangsdaten überführt werden. Die Matrix der Eingangsgrößen X und der Vektor zukünftiger Rollwinkel \vec{y}^* zu einem Zeitpunkt bilden ein Sample. Aus den kontinuierlichen Messdaten werden im Abstand von 0,2 s Samples erzeugt. Die Samples überlappen sich damit stark (min. 96 %), d.h. benachbarte Samples sind sehr ähnlich. Damit wird eine hohe Anzahl an Trainingssamples erreicht. Die große Überlappung muss bei der Aufteilung der Samples in Trainings-, Validierungs- und Testdaten – in den Anteilen 75, 18 und 7 % – berücksichtigt werden. Eine randomisierte Zuteilung in die drei Kategorien ist aufgrund der Ähnlichkeit

benachbarter Samples nicht sinnvoll. Stattdessen werden 20 s lange Sequenzen der Messfahrten randomisiert den drei Kategorien zugeordnet.

Der Samplingalgorithmus wird so gestaltet, dass für alle möglichen Einstellungen der relevanten HP immer die gleichen Zeitpunkte der Messfahrten in den Trainings-, Validierungs- und Testdaten enthalten sind. Damit wird sichergestellt, dass Vergleiche zwischen Modellen während der Optimierung der HP unter fairen, weil gleichen Bedingungen erfolgen.

Bei der Analyse der im Datensatz enthaltenen Querdynamik in Abschnitt 6.2.3 wurde festgestellt, dass die Geradeausfahrt knapp zwei Drittel der Fahrzeit ausmacht. Dieser überrepräsentierte Fahrzustand ist für das Training einer lateralen Trajektorienprädiktion uninteressant und wirkt sich gegebenenfalls sogar negativ auf die Prädiktion in Kurvenfahrt aus, weil eine konservative Prädiktion von Rollwinkeln nahe Null stark belohnt wird. Um den Anteil der Geradeausfahrt in Trainings-, Validierungs- und Testdaten zu verkleinern, bezieht der Samplingalgorithmus das Ergebnis der querdynamischen Manöversegmentierung mit ein und es werden alle Samples verworfen, die ausschließlich Geradeausfahrt enthalten. Dessen Anteil wird dadurch von ursprünglich 64,2 % auf 37,5 % reduziert. Die verbleibende Geradeausfahrt ist diejenige, die vor Beginn oder nach Ende eines querdynamischen Fahrmanövers auftritt und die deshalb innerhalb der Eingangszeitsequenz oder des Prädiktionshorizonts eines Samples vorliegt.

Zum Abschluss der Beschreibung des Modellaufbaus sind in Tabelle 7.3 die $n_F = 16$ Eingangsgrößen des NN-Modells aufgelistet, die basierend auf Expertenwissen aus allen verfügbaren Messsignalen ausgewählt wurden. In der rechten Spalte findet sich jeweils eine kurze Begründung, warum ein Signal für die Rollwinkelprädiktion verwendet wird.

Die neuartigen, am Versuchsmotorrad extra hinzugefügten Messgrößen der Lenkung und des Fahrerverhaltens sind Bestandteil der Forschungsfragen und werden deshalb genutzt. Charakteristische Zustandsgrößen der Querdynamik des Motorrads werden ausgewählt, damit dem Prädiktionsmodell die Identifikation des querdynamischen Verhaltens ermöglicht wird.

Aus den Untersuchungen in Kapitel 5 ist die starke Kopplung des querdynamischen Übertragungsverhaltens mit der Geschwindigkeit bekannt, weshalb längsdynamische Eingaben und Zustände ebenfalls einfließen. Mit der Berücksichtigung von Vertikal- und Querbeschleunigung (Fahrzeug-KS) in den Eingangsgrößen können Störungen durch Straßenanregungen, die sich auf Fahrzustände und besonders das Lenkmoment negativ auswirken, für das NN-Modell teilweise beobachtbar gemacht werden.

Eingangsgröße	Begründung
Rollwinkel, φ / °	Ausgangsgröße, wichtiger querdyn. Fahrzustand
Rollrate*, $\dot{\varphi}$ / °/s	wichtiger querdyn. Fahrzustand
Gierrate*, $\dot{\psi}$ / °/s	wichtiger querdyn. Fahrzustand
Nickrate*, $\dot{\theta}$ / °/s	wichtiger querdyn. Fahrzustand (in Schräglage)
Nickwinkel, θ / °	Identifikation Straßenneigung
Längsgeschwindigkeit, v_x / m/s	Fahrzustand mit großem Einfluss auf Querdynamik
Bremsdruck, p_B / bar	Fahrereingabe Verzögerungswunsch
Längsbeschleunigung*, a_x / m/s ²	Identifikation Beschleunigung & Verzögern
Vertikalbeschleunigung*, a_z / m/s ²	Identifikation Straßenanregung
Querbeschleunigung*, a_y / m/s ²	Identifikation Straßenanregung (in Schräglage)
Lenkmoment*, M_z / Nm	Fahrereingabe für Querdynamik
Lenkwinkel*, δ / °	querdyn. Fahrzustand
Lenkrate*, $\dot{\delta}$ / °/s	querdyn. Fahrzustand
Oberkörperneigung, φ_F / °	Fahrerverhalten in Querdynamik
Lateraler Versatz Oberkörper, $y_{F,M5}$ / cm	Fahrerverhalten in Querdynamik
Kopfdrehwinkel, ψ_H / °	Fahrerverhalten in Querdynamik

Neue Messgrößen: aus Forschungsfragen motiviert

Tabelle 7.3: Auswahl der Eingangsgrößen für die Rollwinkelprädiktion mit Begründung. Signale von vergleichsweise höherer Dynamik sind mit einem „*“ gekennzeichnet.

7.4 Optimierung des Prädiktionsmodells

Zur Erarbeitung des finalen Prädiktionsmodells, welches am Ende dieses Abschnitts vorgestellt wird, werden mehrere HP-Optimierungen, Experimente und manuelle Parametervariationen durchgeführt. Abbildung 7.5 stellt eine Übersicht der Entwicklungsschritte in Form eines Ablaufdiagramms dar, in dem rechts neben jedem Schritt die entscheidenden Ergebnisse stichwortartig notiert sind. Sie dient als roter Faden für die Erläuterungen in diesem Abschnitt, in denen ausgewählte Ergebnisse aus den einzelnen Schritten vorgestellt werden.

Ausgangspunkt der Optimierung ist das im vorherigen Abschnitt 7.3 eingeführte parametrische Prädiktionsmodell, welches aus dem Zeitverlauf von 16 Eingangssignalen die Rollwinkelprädiktion berechnet. Weil gegenseitige Wechselwirkungen der HP bestehen können, wird die gleichzeitige Variation mehrerer Parameter in sogenannten HP-Optimierungen durchgeführt. Dafür wird die in Python verfügbare Optimierungs-Software Optuna [94] eingesetzt, mit der große Suchräume effizient, d.h. schneller als es durch einen vollfaktoriellen Versuch möglich wäre, auf optimale Parametereinstellungen untersucht werden können.

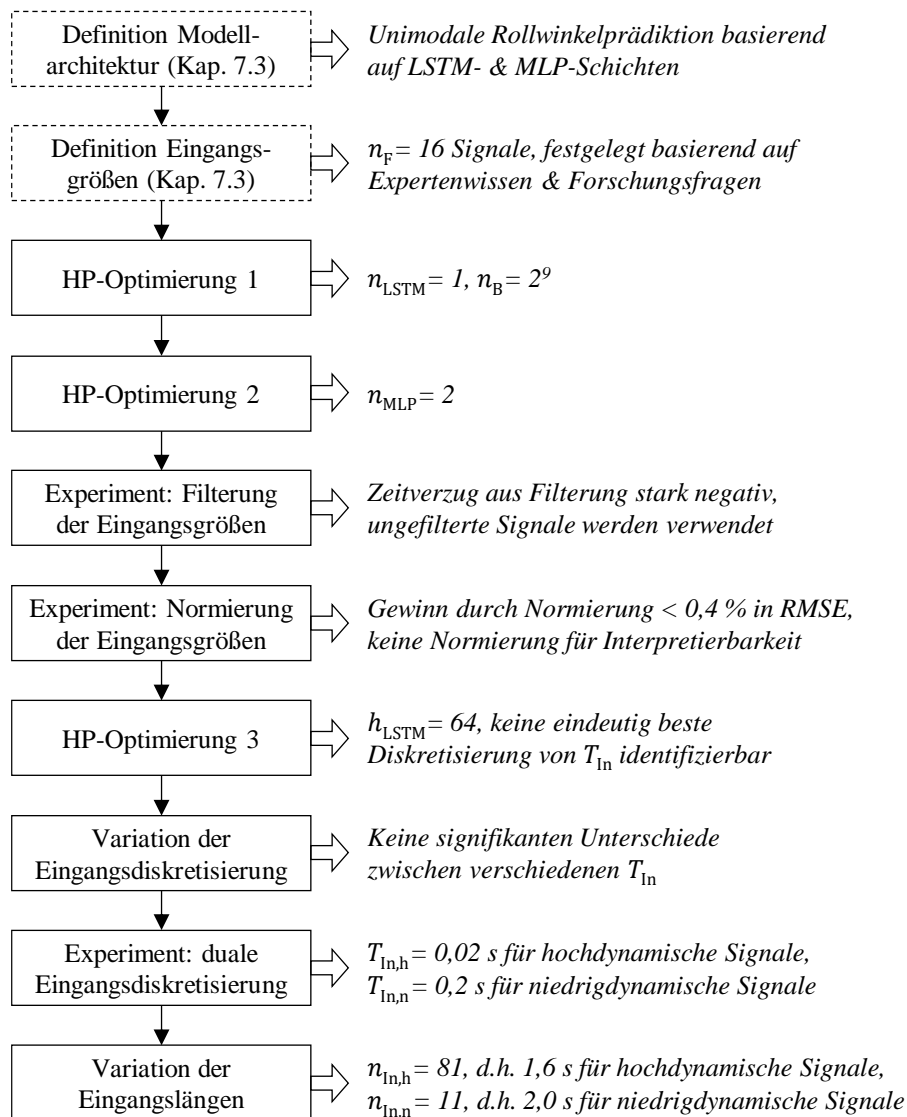


Abbildung 7.5: Schritte der Modellentwicklung (links) mit den wichtigsten Ergebnissen (rechts).

In einer ersten HP-Optimierung werden die zwei Trainings-HP Batchgröße n_B und Lernrate α_L sowie die zwei Architektur-HP Anzahl n_{LSTM} und Größe h_{LSTM} der LSTM-Schichten entsprechend der in Tabelle 7.1 und Tabelle 7.2 definierten Wertebereiche variiert. Die Einstellungen der anderen, konstant gehaltenen HP kann für alle HP-Optimierungen in Anhang A.7 eingesehen werden. Im Rahmen dieser Optimierung werden 160 Versuche, d.h. vollständige Trainings eines Prädiktionsmodells, durchgeführt, von denen 23 Modelle einen MSE von weniger als 52^{02} erreichen. Alle diese besten Modelle besitzen nur eine LSTM-Schicht, weshalb $n_{LSTM} = 1$ für die weitere Entwicklung festgelegt wird. Der Wert von h_{LSTM} beträgt in neun Fällen 64, in je sechs Fällen 96 und 128, sowie in zwei Fällen 160, womit kein eindeutiges Optimum erkennbar ist; h_{LSTM} wird deshalb in der folgenden zweiten HP-Optimierung nochmals variiert. Die Einstellungen der beiden Trainings-HP n_B und α_L unterscheiden sich deutlich unter den besten Modellen; es besteht der Zusammenhang, dass

eine größere Anzahl an Samples je Batch eine höhere Lernrate verlangt. Letztlich zeigt das Ergebnis, dass mit verschiedenen n_B ein niedriger MSE erreicht werden kann. Für alle weiteren Trainings wird n_B auf den Wert 2^9 festgelegt, den Median aller besten Modelle.

In einer zweiten HP-Optimierung mit ebenfalls 160 Versuchen werden erneut die HP α_L und h_{LSTM} variiert; entsprechend des erkannten Zusammenhangs von n_B und α_L kann der Wertebereich von α_L auf $3 \cdot 10^{-5}$ bis $3 \cdot 10^{-3}$ verkleinert werden. Außerdem werden jetzt die zwei Architektur-HP Anzahl der Schichten im MLP n_{MLP} und Länge der Eingangszeitreihe n_{In} variiert. Aus allen Versuchen der zweiten HP-Optimierung werden die besten 10 % aller Prädiktionsmodelle betrachtet. Von diesen besitzen 81 % ein n_{MLP} von zwei, weshalb der HP auf diesen Wert festgelegt wird. Mit einer Häufigkeit von 56 % ist ein h_{LSTM} von 64 erneut am häufigsten aufgetreten. Die in den besten Prädiktionsmodellen vertretenen n_{In} entsprechen Zeitdauern zwischen 6 und 10 s. Sowohl für h_{LSTM} als auch n_{In} kann aus dem Ergebnis der HP-Optimierung keine beste Einstellung abgelesen werden, weshalb beide HP in der dritten Optimierung erneut variiert werden.

Unter Verwendung der bisher vielversprechendsten HP aus beiden Optimierungen werden zwei Experimente bzgl. des Effekts von Filterung und Normierung der Eingangsgrößen durchgeführt. Mit der Filterung der Eingangsgrößen wird geprüft, ob die Reduktion von Rauschen und Störungen in den Messsignalen die Prädiktion verbessert. Es wird auf alle 16 Eingangsgrößen derselbe 2 Hz Tiefpassfilter (online-fähig, d.h. nur Vorwärtsfilterung) angewendet, damit der dadurch induzierte Zeitverzug auf alle Signale gleich wirkt und die korrekte zeitliche Relation zwischen den Größen erhalten bleibt.

In Abbildung 7.6 ist die Prädiktionsgüte der Modelle mit gefilterten und ungefilterten Eingangsgrößen anhand des Rollwinkel-RMSE gegenübergestellt; auf der linken Achse sind die absoluten Verläufe von $RMSE_i(\varphi_i, \varphi_i^*)$ und auf der rechten Achse die Differenz beider Modelle dargestellt. Über den gesamten Prädiktionshorizont besitzt die auf ungefilterten Eingangsgrößen basierende Prädiktion einen niedrigeren Fehler, was an den durchweg positiven Differenzen (grüne Datenpunkte) erkennbar ist; im Mittel ist der $RMSE_i(\varphi_i, \varphi_i^*)$ bei gefilterten Eingangsgrößen um 5 % höher. Auffällig ist, dass die Differenz beider Modelle bis zum Prädiktionshorizont von 0,8 s stark anwächst, darüber hinaus aber keine weitere Verschlechterung durch die Filterung mehr auftritt, sondern die Differenz sogar wieder abnimmt. Demnach wirkt sich der durch die Filterung induzierte Zeitverzug besonders negativ auf die kurzfristige Prädiktionsgüte aus. Weil sich der vermutete Vorteil glatterer Signale nicht einstellt, ist davon auszugehen, dass die LSTM-Schicht einen besseren nichtlinearen Filter während des Trainings auf ungefilterten Signalen erlernt.




Abbildung 7.6: Effekt der Filterung von Eingangssignalen anhand des Verhaltens des Rollwinkel-RMSE über dem Prädiktionshorizont.

Für die Normierung wird die Standardabweichung jedes Eingangssignals in den Trainingsdaten ermittelt und anschließend durch diese dividiert. Eine Normierung des Mittelwerts wird nicht durchgeführt, damit die physikalische Bedeutung von Nullpunkten in den Messgrößen erhalten bleibt, z.B. 0° Rollwinkel für die Geradeausfahrt. Der Vorteil der Normierung in Rollwinkel und Positionstrajektorie ($\text{RMSE}(\vec{\varphi}, \vec{\varphi}^*)$ & $\text{RMSE}(\vec{d}_{\text{Lat}})$) ist kleiner 0,4 %. Ein Grund für den geringen Unterschied wird mitunter sein, dass bei der Wahl der Einheiten der Eingangsgrößen (siehe Tabelle 7.3) bereits auf ähnliche Größenordnungen geachtet wurde. Dass Normierung von Fahrdynamikgrößen in NN-Modellen keine signifikante Verbesserung bewirkt, ist auch in den Untersuchungen von Immel [60] beschrieben. Im Sinne der Interpretierbarkeit der Eingangssignale wird entschieden, dass keine Normierung erfolgt.

In der dritten HP-Optimierung werden erneut α_L , h_{LSTM} und n_{In} sowie zum ersten Mal die Diskretisierung der Eingangssignale T_{In} variiert. Von den besten Modellen (14 % der 160 Versuche) haben 82 % die gleiche Zellanzahl von 64 in der LSTM-Schicht, weshalb h_{LSTM} auf diesen Wert festgelegt wird; entsprechend der in Tabelle 7.1 beschriebenen Zwangsbedingungen ist damit auch die Größe der zwei linearen Schichten des MLP auf 64 und 32 Neuronen definiert. Der Median von n_{In} beträgt 81 und die überwiegende Zahl der besten Modelle besitzt eine Diskretisierung T_{In} von 0,2 s. Jedoch treten ebenso gute Modelle mit 0,02 s Diskretisierung auf, was unplausibel erscheint und deshalb genauer untersucht wird.

Mit einer manuellen Variation der vier Einstellungen von T_{In} (0,02; 0,05; 0,1; 0,2 s), während derer alle anderen HP konstant bleiben, wird der Effekt der Diskretisierung der Eingangssignale isoliert untersucht. Im $\text{RMSE}(\vec{\varphi}, \vec{\varphi}^*)$ unterscheiden sich die vier Einstellungen um weniger als 1 %, eine Darstellung der quasi deckungsgleichen Verläufe von $\text{RMSE}_i(\varphi_i, \varphi_i^*)$ über dem Prädiktionshorizont ist deshalb nicht sinnvoll. Eine mögliche Erklärung für das nahezu identische Verhalten bei unterschiedlicher Eingangs-Diskretisierung ist, dass sich positive und negative Effekte verschiedener T_{In} gegenseitig aufheben. So ist z.B. eine feine Diskretisierung

positiv für verrauschte bzw. hochdynamische Signale, die sonst nicht korrekt abgetastet werden (Aliasing), sie wirkt sich aber negativ auf die Fähigkeit des RNN aus, längere zeitliche Zusammenhänge zu interpretieren. Denn wenn ein Signal von niedriger Dynamik überabgetastet wird, dann müssen die verborgenen Zustandsvektoren der LSTM-Zellen über unnötig viele rekurrente Rechenschritte Information speichern, um zeitliche Muster zu erkennen.

Aus den unterschiedlichen Anforderungen hoch- und niedrigdynamischer Eingangssignale motiviert sich die Idee, zwei unterschiedliche T_{In} in einem Prädiktionsmodell zu kombinieren. Entsprechend werden die hochdynamischen Eingangsgrößen, die in Tabelle 7.3 mit „*“ markiert sind, mit der niedrigsten Diskretisierung ($T_{In}=0,02$ s) und die übrigen Größen mit der höchsten Diskretisierung ($T_{In}=0,2$ s) verarbeitet. Weil bei unterschiedlich diskretisierten Signalen zu einem rekurrenten Rechenschritt im LSTM keine zeitliche Korrelation mehr vorliegt, werden anstatt einer zwei halb so große, unabhängige LSTM-Schichten eingesetzt, die hoch- und niedrigdynamische Eingangsgrößen getrennt verarbeiten. Die Ausgänge beider Schichten werden kombiniert und wie vorher im MLP weiterverarbeitet.

Die Prädiktionsgüte eines Modells mit dualer Diskretisierung ist in Abbildung 7.7 mit den Ergebnissen der manuellen Variation von T_{In} verglichen, indem die Differenz der $RMSE_i(\varphi_i, \varphi_i^*)$ -Verläufe der vier einheitlichen Diskretisierungen zum kombinierten Modell dargestellt wird. Durchweg positive Differenzen zeigen eine eindeutige Verbesserung durch die Verwendung zweier T_{In} ; die Reduktion des $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ gegenüber den vier einheitlichen T_{In} liegt zwischen 4 und 5 %. Dabei ist insbesondere zwischen einer und drei Sekunden auf dem Prädiktionshorizont ein Anstieg der Differenz und damit eine Verbesserung durch die duale Diskretisierung zu erkennen. Die sehr ähnlichen Verläufe der vier Kurven in Abbildung 7.7 verdeutlichen das vorher beschriebene Verhalten, dass die manuelle Variation von T_{In} zu quasi deckungsgleichen Verläufen von $RMSE_i(\varphi_i, \varphi_i^*)$ führt.

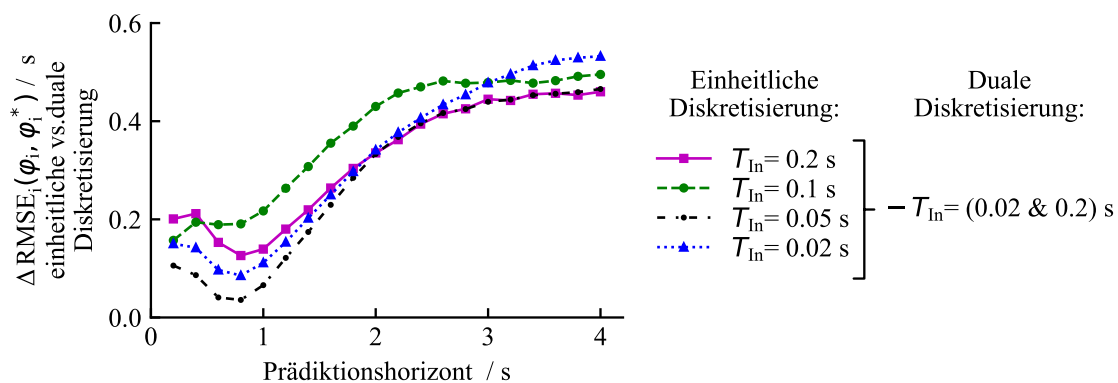


Abbildung 7.7: Ergebnisse der manuellen Variation der Eingangs-Diskretisierung im Vergleich zum Verhalten der dualen Diskretisierung.

7.4 Optimierung des Prädiktionsmodells

Mit dem neuen Konzept der dualen Diskretisierung der Eingangsgrößen ist der HP T_{In} festgelegt. Weil sich das Verhalten des Prädiktionsmodells durch die Auftrennung in zwei unabhängige LSTM-Schichten am Modelleingang nicht grundlegend verändert, werden die in den vorherigen Optimierungen ermittelten Parametereinstellungen beibehalten. Damit verbleiben als letzte zu bestimmende HP die Längen der Eingangszeitreihen $n_{In,h}$ und $n_{In,n}$ für die zwei Gruppen der hoch- und niedrigdynamischen Signale. Es wird eine vollfaktorielle Variation beider Parameter durchgeführt. Zur Auswahl der besten Parameterpaarung werden neben dem $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ auch zwei Metriken auf Positionsebene betrachtet: der Mittelwert des Evaluationsindex (\overline{EI}) und die Anzahl an Testsamples mit einem EI kleiner 2 s ($n(EI < 2\text{ s})$). Für jede Metrik wird die relative Ausprägung bzgl. der schlechtesten (0 %) und besten (100 %) Einstellung bewertet. Aus den drei einzelnen Bewertungen wird anschließend eine gewichtete Summe gebildet, sodass Rollwinkel und laterale Abweichung jeweils zur Hälfte in die Gesamtbewertung eingehen.

Die besten vier Einstellungen von $n_{In,h}$ und $n_{In,n}$ sowie deren relative Prädiktionsgüte in den drei Metriken und die Gesamtbewertung sind in Tabelle 7.4 aufgeführt. Die mit Abstand beste Prädiktionsgüte erreicht das Modell mit 2 s langer Eingangszeitreihe für niedrigdynamische und 1,6 s für hochdynamische Eingangssignale.

HP-Einstellung Länge des Eingangs		Kriterium: Relative Ausprägung der einzelnen Metriken (0-100 % \triangleq „Schlechteste bis Beste“)			Gesamt- bewertung
$n_{In,n}$	$n_{In,h}$	A: $RMSE(\vec{\varphi}, \vec{\varphi}^*)$	B: \overline{EI}	C: $n(EI < 2\text{ s})$	$A+(B+C)/2$
11 \triangleq 2 s	81 \triangleq 1,6 s	98	82	81	179,5
11 \triangleq 2 s	31 \triangleq 0,6 s	78	100	68	162,0
51 \triangleq 10 s	81 \triangleq 1,6 s	100	72	30	151,0
31 \triangleq 6 s	81 \triangleq 1,6 s	85	82	46	149,0

Tabelle 7.4: Top 4 Einstellungen der Parametervariation der Eingangszeitreihen-Längen mit Bewertung entsprechend Rollwinkelfehler und Evaluationsindex.

Mit der Festlegung der optimalen Längen der Eingangszeitreihen ist die Optimierung der HP entsprechend der in Tabelle 7.1 und Tabelle 7.2 definierten Wertebereiche und Zwangsbedingungen abgeschlossen. Als Zusammenfassung ist in Abbildung 7.8 die finale Architektur des NN-Modells mit dualer Diskretisierung zur Vorhersage des Rollwinkels dargestellt. Eingezeichnet sind alle ermittelten Werte der HP und die Dimensionalität des Datenflusses zwischen den NN-Schichten. Das Modell besitzt 17396 trainierbare Gewichte in allen Schichten. Rund eine halbe Million Multiplikationen und Additionen sind für die Berechnung einer Prädiktion ($n_B = 1$) durchzuführen. Im Kontext der Trajektorienprädiktion handelt es sich

damit um ein vergleichsweise kleines NN-Modell, weil zum einen ausschließlich Zeitreihendaten und keine 2D- oder 3D-Umgebungsinformationen verarbeitet werden. Zum anderen ist die unimodale Prädiktion weniger komplex als eine multimodale bei gleichen Eingängen.

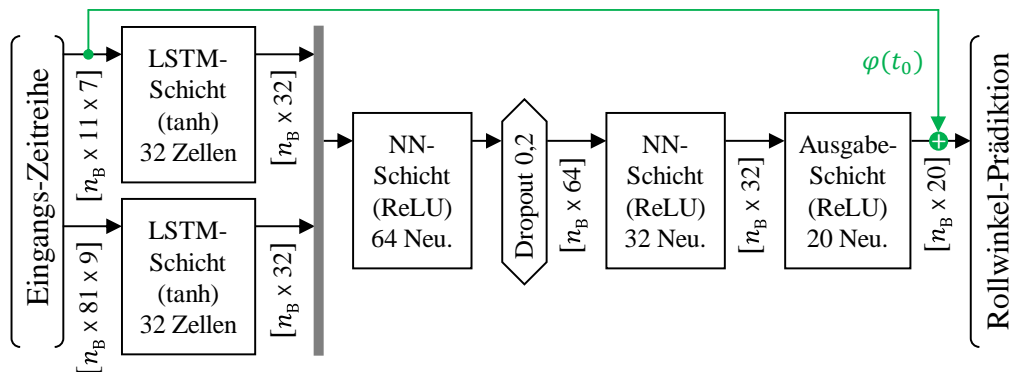


Abbildung 7.8: Finale Architektur und Dimensionalität des Datenflusses im Rollwinkelprädiktionsmodell.

Die Prädiktionsgüte des final optimierten Prädiktionsmodells wird im Kapitel 8 ausführlich auf den Testdaten der Datenerhebung untersucht und dem Verhalten des im folgenden beschriebenen Benchmark-Modells gegenübergestellt.

7.5 Standardbewegungsmodell als Benchmark

Entsprechend der ersten, in Abschnitt 1.4 formulierten, Forschungsfrage soll die Prädiktionsgüte der motorradspezifischen Trajektorienprädiktion einem Standardbewegungsmodell (SB) gegenübergestellt werden. In diesem Abschnitt werden deshalb zwei einfache Annahmen der Trajektorienprädiktion anhand des Testdatensatzes verglichen. Die besser abschneidende Annahme wird in Abschnitt 8.1 als SB in den Vergleich zur manöverbasierten Trajektorienprädiktion gesetzt.

Im SAE J2945/1-Standard über die Systemanforderungen an C-ITS fähige Fahrzeuge wird eine rein auf den Fahrdynamikzuständen basierende physikalische Trajektorienprädiktion vorgeschlagen [95]. Hierbei wird aus Gierrate und Geschwindigkeit die zum Zeitpunkt vorliegende Krümmung des Pfades errechnet, welche über den gesamten Prädiktionshorizont konstant fortgeschrieben wird. Dies entspricht der Annahme einer konstanten Kurvenfahrt. Das CMC [22] untersucht das Verhalten dieses Ansatzes in Simulationen für das Motorrad und vergleicht dabei verschiedene Möglichkeiten zur Bestimmung der Krümmung. Neben der Verwendung der Gierrate im Fahrzeug-KS (wie im PKW), was aufgrund des Rollwinkels in Kurvenfahrt fehlerbehaftet ist, wird die Krümmung wahlweise aus horizontaler Gierrate, Rollwinkel oder kinematischem Lenkwinkel errechnet. Insgesamt wird von sehr ähnlichem Verhalten aller Varianten berichtet. Zudem betrachten die Autoren die Annahme von

Krümmung null, d.h. dem Beibehalten des aktuellen Gierwinkels über dem Prädiktionshorizont, und berichten von vergleichbar schlechter Prädiktionsgüte.

Am vorliegenden Testdatensatz werden die Annahmen konstanter Kurvenfahrt und Geradeausfahrt über dem Prädiktionshorizont analysiert, indem für erstere das Beibehalten des aktuellen Rollwinkels $\varphi(t_0)$ und für zweitere Rollwinkel Null angenommen wird. Die resultierenden $\text{RMSE}_i(\varphi_i, \varphi_i^*)$ sind mit runden Markern über der linken Achse in Abbildung 7.9a dargestellt. Hierbei ist für die erste Hälfte des Prädiktionshorizonts ein deutlicher Vorteil für konstant gehaltenes $\varphi(t_0)$ zu erkennen, ab 2 s Vorausschau führt hingegen die Annahme der Geradeausfahrt zu niedrigeren Fehlern.

Entsprechend dem in Abschnitt 7.2 beschriebenen Vorgehen werden die Rollwinkel- in Positionstrajektorien überführt, sodass lateraler Positionsfehler und Evaluationsindex ausgewertet werden können. Im mit dreieckigen Markern in Abbildung 7.9a dargestellten Verlauf von $\text{RMSE}_i(d_{\text{Lat},i})$ zeigt sich eine deutlich schlechtere Prädiktion über den gesamten Prädiktionshorizont bei Annahme der Geradeausfahrt (rot). Die Verteilung des EI in Abbildung 7.9b verdeutlicht den Vorteil der Annahme konstanter Kurvenfahrt (grau) auf Positionsebene; für Rollwinkel Null liegt der EI in 47 % aller Testsamples unterhalb von 2 s, für konstanten Rollwinkel hingegen nur in 12 %.

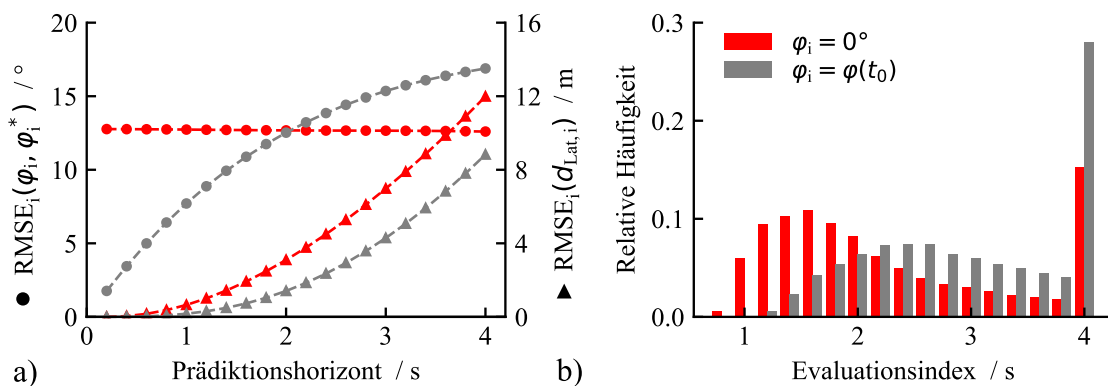


Abbildung 7.9: Prädiktionsgüte der einfachen Annahmen der Geradeausfahrt (rot) und der konstanten Kurvenfahrt (grau) in verschiedenen Metriken, ausgewertet auf dem Testdatensatz.

In Anbetracht der eindeutig besseren Prädiktionsgüte bei Annahme konstanter Kurvenfahrt über dem Prädiktionshorizont wird diese als SB für den Vergleich mit der motorradspezifischen lateralen Trajektorienprädiktion herangezogen.

8 Ergebnisse der lateralen Trajektorienprädiktion

Das in Kapitel 7 entwickelte NN-Modell für die laterale Trajektorienprädiktion des Motorrads wird in diesem Kapitel ausführlich getestet. Es bezieht neben den Fahrdynamikdaten auch Zustandsgrößen der Lenkung, laterale Oberkörperbewegung, die Lenkmomenteingabe und Kopfdrehung des Fahrers in die Prädiktion einer Rollwinkeltrajektorie ein. Dieses Modell wird im Folgenden zur besseren Lesbarkeit kurz als „Vollmodell“ bezeichnet. In Abschnitt 8.1 wird dessen Prädiktionsgüte auf dem Testdatensatz – der 7 % der Realfahrdaten darstellt – vorgestellt und mit dem Standardbewegungsmodell (SB) konstanter Kurvenfahrt verglichen. Abschnitt 8.2 nutzt die Klassifizierung der Querdynamik in Form der Manöversegmentierung, um das Verhalten des Vollmodells systematisch in verschiedenen Fahrsituationen zu analysieren. Die ausführliche Kreuzvalidierung des Vollmodells ermöglicht in Abschnitt 8.3 die fahrtindividuelle Bewertung der Prädiktionsgüte. Es wird geprüft, inwiefern die – in Abschnitt 6.3 analysierten – unterschiedlichen Fahrweisen und Fahrstile der Testfahrer die Prädiktion beeinflussen.

Für die Beantwortung der Forschungsfrage RQ3 – zur Bedeutung der neuartigen Messgrößen der Zustandsgrößen der Lenkung und querdynamischer Fahrereingaben für eine laterale Trajektorienprädiktion – wird in Abschnitt 8.4 eine ausführliche Ablationsstudie auf den Testdaten durchgeführt. Unter anderem wird hierbei auch die Prädiktionsgüte eines RNN-basierten „Standardmodells“ aufgezeigt, welches ausschließlich Eingangsgrößen verwendet, die auf heutigen Serienmotorrädern verfügbar sind.

Das realisierte NN-Prädiktionsmodell behandelt mit der Berechnung einer Rollwinkeltrajektorie bewusst nur die querdynamische Komponente der Trajektorienprädiktion. Für die Längsdynamik wird die Geschwindigkeit zum Zeitpunkt der Prädiktion als konstant über den gesamten Prädiktionshorizont angenommen. In Abschnitt 8.5 ist die Auswirkung dieser Annahme auf die lateralen Metriken der Trajektorienprädiktion beschrieben und es werden in Pilotexperimenten mögliche Ansätze zur manöverbasierten Längsdynamikprädiktion und kombinierten längs- und querdynamischen Trajektorienprädiktion beleuchtet. Anhand der dargestellten Ergebnisse werden in Abschnitt 8.6 die Forschungsfragen aus Abschnitt 1.4 beantwortet und der gewählte Ansatz einer manöverbasierten lateralen Trajektorienprädiktion wird bzgl. seiner Potenziale und Limitierungen diskutiert.

8.1 Verbesserung gegenüber Standardbewegungsmodell

Mit dem Verlauf des Rollwinkelfehlers über dem Prädiktionshorizont wird in Abbildung 8.1a zuerst die direkte Ausgabe des NN-Prädiktionsmodells betrachtet. Die Werte $RMSE_i(\varphi_i, \varphi_i^*)$ des Vollmodells, dargestellt in blauen Punkten, sind im Mittel über alle 20 Prädiktionspunkte um 45 % niedriger als die des SB mit der Annahme konstanter Kurvenfahrt ($\varphi_i = \varphi(t_0)$) in schwarzen Rauten. Wird der Gesamtfehler des Rollwinkels $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ aller Punkte berechnet, so ist dieser mit $7,7^\circ$ für das Vollmodell um 39 % niedriger als die $12,5^\circ$ des SB. Ein Differenz-Verlauf $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ von SB und Vollmodell ist in Abbildung 8.1a mit pinken Dreiecken dargestellt. Der hohe positive Gradient innerhalb der ersten Sekunde der Prädiktion zeigt, dass in diesem Bereich eine deutliche Verbesserung durch das Vollmodell gegenüber dem SB vorliegt. Mit zunehmender Vorausschauzeit nimmt der Gradient des Verlaufs von $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ ab, bleibt jedoch immer positiv, d.h. die Verbesserung gegenüber dem SB wird – wenngleich nur noch geringfügig – bis zur maximalen Prädiktionszeit von vier Sekunden gesteigert.

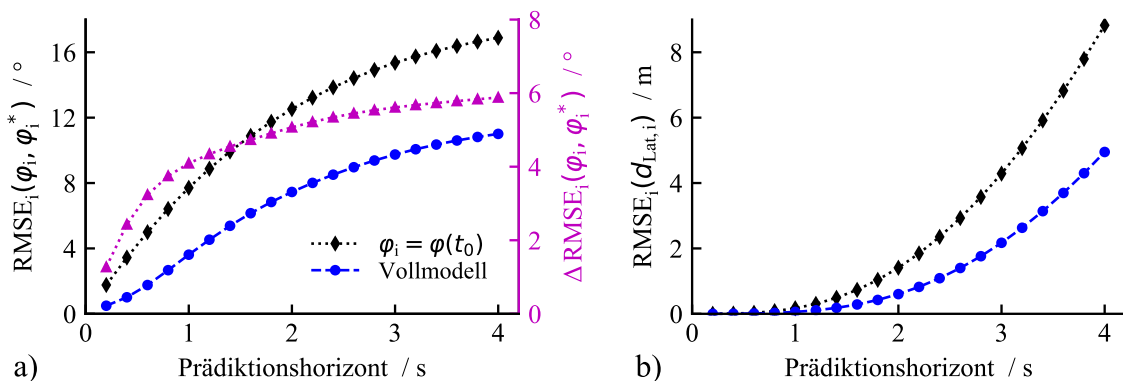


Abbildung 8.1: Vergleich von Vollmodell und Standardbewegungsmodell konstanter Kurvenfahrt in: a) Rollwinkel-RMSE und b) RMSE des lateralen Positionsfehlers über dem Prädiktionshorizont.

Abbildung 8.1b zeigt den Verlauf des lateralen Positionsfehlers über dem Prädiktionshorizont, nachdem die Rollwinkel- in Positionstrajektorien transformiert wurden. Im Durchschnitt sind die $RMSE_i(d_{Lat,i})$ des Vollmodells um 52 % reduziert gegenüber denen des SB. Der Gesamtfehler der lateralen Abweichung $RMSE(\vec{d}_{Lat})$ beträgt für das Vollmodell 2,1 m, was einer Reduktion von 46 % bzgl. dem Fehler des SB von 3,9 m entspricht. Diese relative Verbesserung von Vollmodell gegenüber SB ist auf Positionsebene größer als im Rollwinkel, weil die Transformation in Positionen integrierenden Charakter hat. Die erläuterte starke Verbesserung der Rollwinkelprädiktion innerhalb der ersten Sekunde der Prädiktion wirkt sich deshalb deutlich auf die lateralen Positionsfehler über den gesamten Prädiktionshorizont aus. Die Vorausschauzeiten mit akzeptabler lateraler Positionsgenauigkeit (EI-Metrik) wird, wie in Abschnitt 7.2 erläutert, mit einem Genauigkeits-Grenzwert des lateralen Positionsfehlers von

2 m ausgewertet (dies gilt für alle in Kapitel 8 beschriebenen Auswertungen des EI). Abbildung 8.2a zeigt die resultierenden EI-Werte von Vollmodell und SB für alle Testsamples in Histogrammen. Wie erwartet, erreicht das Vollmodell dank des deutlich reduzierten lateralen Positionsfehlers signifikant höhere EI, im Mittelwert steigt der EI von 2,99 s für das SB auf 3,42 s für das Vollmodell (im Median von 3,0 auf 3,6 s). Mit dem Vollmodell wird in 98,6 % der Testsituationen ein EI von mindestens 2 s und in 71,2 % von mehr als 3 s erreicht. Letzteres entspricht einer Steigerung um 52 % im Vergleich zum SB.




Abbildung 8.2: Evaluationsindex (EI) von Vollmodell und Standardbewegungsmodell konstanter Kurvenfahrt: a) Verteilung über Testdaten, b) Verbesserung des Vollmodells in Situationen mit EI < 2 s.

Die Anzahl an Testsamples mit einem EI kleiner zwei Sekunden ($n(EI < 2$ s)) wird durch das Vollmodell besonders stark, nämlich um 89 % gegenüber dem SB, reduziert. Wie stark die Steigerung des EI in diesen Situationen ($EI < 2$ s für das SB) ausfällt, zeigt der Boxplot in Abbildung 8.2b; im Median kann die Vorausschauzeit um 1 s erhöht werden.

Das allgemeine Verhalten der RNN-basierten lateralen Trajektorienprädiktion ist exemplarisch anhand der Darstellung einzelner Prädiktionen in einem Beispielmanöver in Anhang A.8 aufgezeigt. Darin ist sichtbar, dass die in Abschnitt 7.4 optimierte Modellarchitektur sehr stetige Verläufe der Rollwinkeltrajektorien bewirkt, die teilweise glatter sind als die real Gefahrenen.

8.2 Manöverspezifisches Verhalten der Prädiktion

Um genauer zu verstehen, wie sich die RNN-basierte laterale Trajektorienprädiktion in Form des Vollmodells in unterschiedlichen Fahrsituationen verhält, werden die Testsamples entsprechend ihres querdynamischen Manöversegments (MS, siehe Abschnitt 6.2) zum aktuellen Zeitpunkt der Prädiktion (t_0) getrennt ausgewertet. Die Ergebnisse werden in Relation zum SB mit der Annahme konstanten Rollwinkels gesetzt.

Abbildung 8.3a zeigt die relative Verbesserung des Vollmodells gegenüber dem SB in Form der Reduktion des Gesamtfehlers des Rollwinkels $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ für die neun

8.2 Manöverspezifisches Verhalten der Prädiktion

richtungsabhängigen MS. Dabei sind in quasistationärer Kurvenfahrt (C) und Schräglagenaufbau (RI) Unterschiede zwischen den Kurvenrichtungen zu erkennen. Die Analyse der Prädiktionen von Vollmodell und SB offenbart dafür unterschiedliche Ursachen. Für C liegt eine bessere Prädiktionsgüte des SB in Rechtskurven vor, weshalb das Vollmodell in C_R eine geringere Verbesserung des $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ verglichen zu C_L erzielt; eine bessere Funktion des SB in eine Kurvenrichtung kann durch die Streckencharakteristik oder Fahrweise der Testfahrer begründet sein. Für RI besteht hingegen unterschiedliches Verhalten des Vollmodells, welches in RI_L (z.B. bei Einfahrt in eine Linkskurve) eine höhere Prädiktionsgüte erreicht; hierfür können unterschiedliche Fahrweisen in den Kurvenrichtungen ursächlich sein. Beispielsweise nutzt, wie in Abbildung 6.8b dargestellt ist, die Mehrzahl der Testfahrer in Linkskurven weniger maximale Schräglage als in Rechtskurven. Folglich gibt es weniger mögliche Endrollwinkel beim Abschluss des Schräglagenaufbaus, welcher noch während der 4 s Prädiktionszeit eintreten wird (siehe Zeitdauer transienter MS in Abbildung 6.6b).

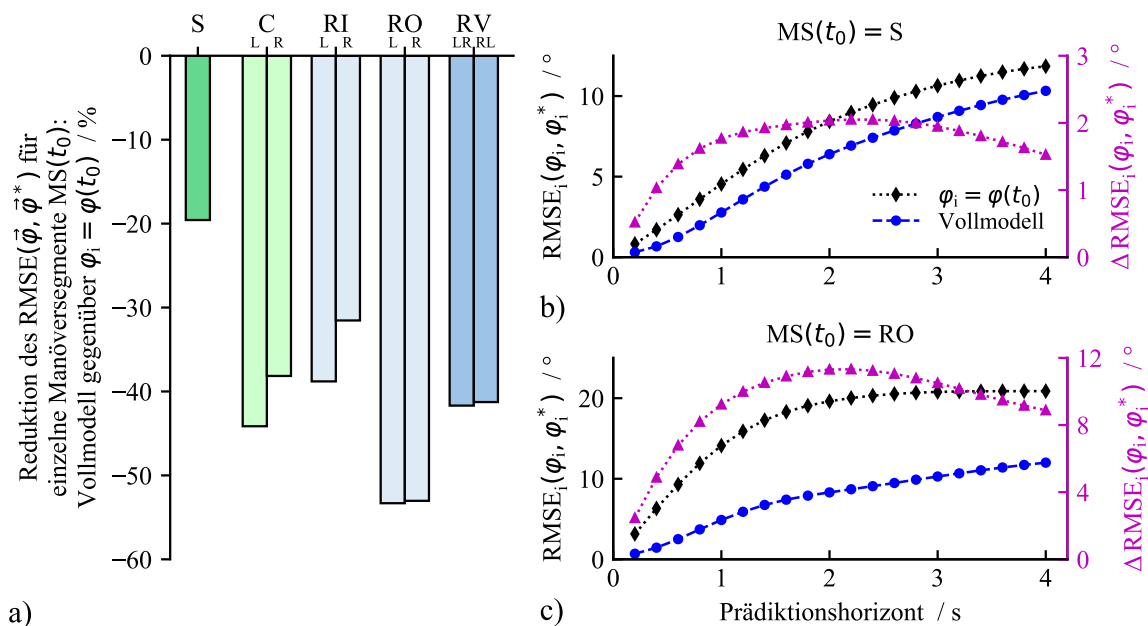


Abbildung 8.3: Prädiktionsgüte des Rollwinkels aufgeschlüsselt nach Manöversegmenten (MS).

Dass mit etwa -20 % Reduktion des $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ in Situationen der Geradeausfahrt (S) die geringste Verbesserung durch das Vollmodell erreicht wird, wurde erwartet. Zum einen, weil in S die geringsten absoluten Fehler des SB vorliegen und deshalb das Verbesserungspotential kleiner ist – Tabelle 8.1 zeigt die Absolutwerte verschiedener Metriken für Vollmodell und SB, aufgeschlüsselt nach dem MS zum aktuellen Zeitpunkt der Prädiktion (t_0). Zum anderen ist die Vorhersage des Beginns von Schräglagenaufbauten, die häufig auf dem Prädiktionshorizont liegen, wenn man sich aktuell in S befindet, auch für das Vollmodell schwierig.

Abbildung 8.3b zeigt die $RMSE_i(\varphi_i, \varphi_i^*)$ -Verläufe von Vollmodell und SB für alle Testsamples der Geradeausfahrt. Die Differenz beider Kurven in pinken Dreiecken (SB minus Vollmodell)

zeigt, dass der Vorteil des Vollmodells hauptsächlich in der ersten Sekunde der Prädiktion aufgebaut wird.

Im Schräglagenabbau (RO) wird mit über -50 % Reduktion die höchste relative Verbesserung erreicht. Dies ist nachvollziehbar, weil die meisten RO in Geradeausfahrt enden (nur 16 % der RO münden in einen Schräglagenwechsel) und die Rollwinkelprädiktion in dieser Situation vergleichsweise einfach durch das RNN zu erlernen ist. In den $RMSE_i(\varphi_i, \varphi_i^*)$ -Verläufen für die RO-Testsamples in Abbildung 8.3c ist bis zu 12° Differenz vorhanden, die in den ersten zwei Sekunden Prädiktionszeit aufgebaut wird. Weil aus den Untersuchungen zur Manöversegmentierung in Abschnitt 6.2.3 bekannt ist, dass 90 % der RO weniger als 2 s dauern, ist es nicht verwunderlich, dass darüber hinaus keine weitere Verbesserung der Prädiktion durch das Vollmodell erfolgt.

Bei Betrachtung der Absolutwerte der diversen Metriken in Tabelle 8.1 fällt auf, dass das Vollmodell (fett hervorgehobene Werte) im Gegensatz zum SB die interessante Eigenschaft aufweist, im MS der quasistationären Kurvenfahrt ähnliche Prädiktionsgüte wie in der Geradeausfahrt zu erreichen (z.B. lateraler Positionsfehler $RMSE(\vec{d}_{Lat})$).

$MS(t_0)$	$RMSE(\vec{\varphi}, \vec{\varphi}^*) / ^\circ$		$RMSE(\vec{d}_{Lat}) / m$		\overline{EI} / s		$n(EI < 2 s) / \%$	
S	6,8	8,5	1,8	2,6	3,51	3,25	0,5	3,2
$C_L C_R$	7,0 7,3	12,5 11,8	1,8 1,9	3,3 3,3	3,51 3,48	3,14 3,14	0,7 0,9	6,1 6,5
$RI_L RI_R$	9,1 10,6	14,9 15,5	2,6 2,9	4,7 4,6	3,15 3,09	2,56 2,54	3,0 4,2	26,2 26,8
$RO_L RO_R$	8,5 8,2	18,3 17,5	2,5 2,3	6,5 6,2	3,30 3,30	2,30 2,36	2,5 2,3	40,2 35,7
$RV_{LR} RV_{RL}$	10,3 11,3	17,6 19,2	2,9 3,0	6,0 6,1	3,02 3,04	2,26 2,18	5,5 5,6	42,7 48,7

Tabelle 8.1: Metriken der lateralen Trajektorienprädiktion von Vollmodell (jeweils links, fett) und SB konstanter Kurvenfahrt (jeweils rechts) nach Manöversegmenten zum aktuellen Zeitpunkt $MS(t_0)$.

Weiterhin wird betrachtet, inwiefern die Güte der lateralen Trajektorienprädiktion eine Abhängigkeit von der Geschwindigkeit aufweist. Dazu werden die Testsamples entsprechend ihrer Geschwindigkeit zum aktuellen Zeitpunkt der Prädiktion $v_x(t_0)$ in vier Gruppen aufgeteilt. Die Geschwindigkeitsbereiche der Gruppen und der Anteil der Testdaten, der diesen zugeordnet wird, sind in der Legende der Abbildung 8.4a angegeben. Zur Bewertung der Prädiktionsgüte werden der EI und daraus abgeleitete Metriken betrachtet.

Das Histogramm in Abbildung 8.4a zeigt für das Vollmodell die Verteilung des EI in den vier Geschwindigkeitsbereichen. Insbesondere für kleine EI ist mit zunehmender Geschwindigkeit eine abnehmende Häufigkeit zu erkennen, d.h. es gibt weniger Testsituationen mit geringer Vorausschauzeit – die Prädiktionsgüte ist höher.

8.3 Fahrerspezifisches Verhalten der Prädiktion

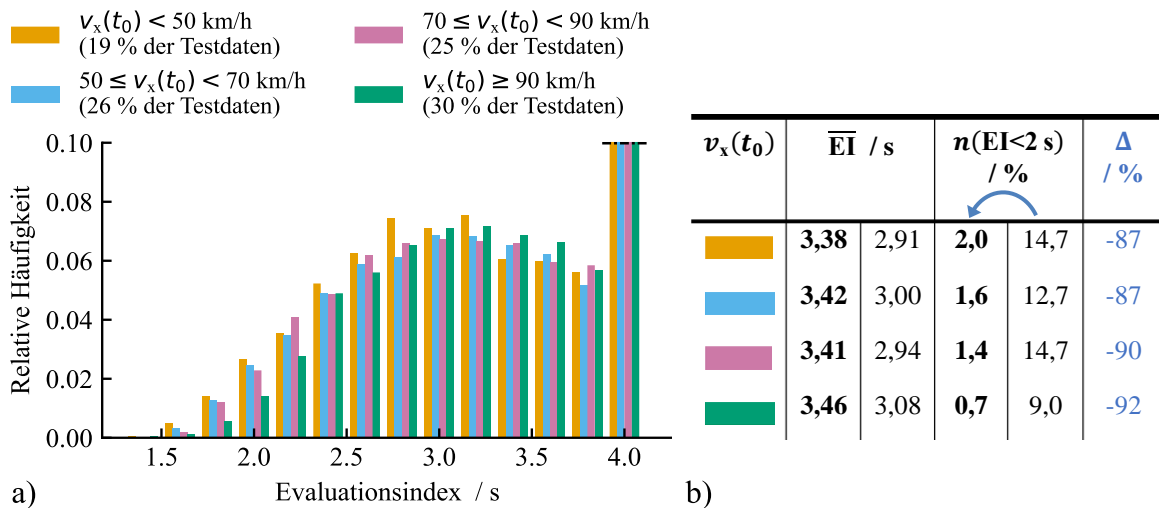


Abbildung 8.4: Evaluationsindex (EI) ausgewertet in vier Geschwindigkeitsbereichen: a) Histogramme des EI für das Vollmodell, b) Vergleich der Metriken von Vollmodell (jeweils links, fett) und Standardbewegungsmodell konstanter Kurvenfahrt (jeweils rechts) mit relativer Verbesserung (blau).

Die Tabelle in Abbildung 8.4b listet die Metriken des mittleren EI (\overline{EI}) und des Anteils der Situationen mit niedriger Vorhersagezeit ($n(EI < 2 \text{ s})$) für das Vollmodell und das SB konstanter Kurvenfahrt in den vier Geschwindigkeitsbereichen. Weil auch das SB das gleiche Verhalten aufweist, dass im Bereich zwischen 30 und 50 km/h der niedrigste \overline{EI} (und höchste $n(EI < 2 \text{ s})$) und bei mehr als 90 km/h der höchste \overline{EI} (und niedrigste $n(EI < 2 \text{ s})$) vorliegt, wird darauf geschlossen, dass je Geschwindigkeit ein unterschiedlicher Anteil transienter (=schwieriger) Manöver in den Daten vorliegt. In Anhang A.9 sind die Anteile der querdynamischen MS in den vier Bereichen analysiert; die Auswertung zeigt, dass bei mehr als 90 km/h tatsächlich weniger Schräglagenaufbau- und -wechsel-Manöver und deshalb insgesamt weniger transiente Manöver vorhanden sind. In den mittleren zwei Geschwindigkeitsbereichen zeigen die Metriken sehr ähnliche Prädiktionsgüte an.

In der letzten Spalte der Tabelle in Abbildung 8.4b wird die relative Veränderung von $n(EI < 2 \text{ s})$ bei Einsatz des Vollmodells anstelle des SB in Prozent angegeben. Die Reduktion des Anteils der Testsituationen mit niedriger Vorausschauzeit durch das Vollmodell ist konstant hoch und zeigt sogar eine zunehmende Tendenz mit steigender Geschwindigkeit. Die RNN-basierte Rollwinkelprädiktion erreicht demnach für alle betrachteten Geschwindigkeiten eine deutlich verbesserte laterale Trajektorienprädiktion.

8.3 Fahrerspezifisches Verhalten der Prädiktion

Wie in Abschnitt 6.3 beschrieben ist, bestehen zwischen den 21 Fahrern, die in den untersuchten Realfahrdaten vertreten sind, deutliche Unterschiede in der Fahrweise und für manche Fahrer auch im Fahrstil. In diesem Abschnitt wird deshalb untersucht, inwiefern sich

die Güte der manöverbasierten lateralen Trajektorienprädiktion zwischen den Fahrern unterscheidet.

Der alleinige Vergleich von Absolutwerten der Metriken ist dabei wenig aussagekräftig, weil die Fahrer auf unterschiedlichen Strecken gefahren sind, deren unterschiedliche Charakteristiken die Prädiktionsgüte beeinflussen. Es wird deshalb ergänzend für jede Messfahrt das SB konstanter Kurvenfahrt ausgewertet, sodass diesbezüglich eine relative Verbesserung durch das Vollmodell ermittelt werden kann.

Die fahrtindividuelle Auswertung der Prädiktion stellt aufgrund der verfügbaren Datenmenge eine besondere Herausforderung dar, denn ein Anteil von 7 % Testdaten auf eine Fahrt von rund 2 h Länge entspricht nur 8 Minuten. Bei solch einer geringen Menge an Testsamples streut die Verteilung der MS zwischen den Fahrten deutlich. Dass dies einen bedeutenden Einfluss auf die Prädiktionsgüte hat, zeigen die Größenordnungen der MS-individuellen Metriken in Tabelle 8.1 des vorherigen Abschnitts 8.2. Ein Vergleich der einzelnen Messfahrten allein auf Basis des bisher betrachteten Testdatensatzes ist deshalb nicht sinnvoll.

Um die Prädiktionsgüte auf deutlich mehr Fahrsituationen einer jeden Messfahrt zu testen und damit eine statistisch belastbare Aussage zu erhalten, wird die Methode der Kreuzvalidierung eingesetzt (siehe Abschnitt 3.2.3). Es werden insgesamt 20 Läufe durchgeführt, in denen jeweils 7 % der Fahrdaten randomisiert als Testdaten annotiert werden, auf den übrigen Daten ein Vollmodell trainiert und abschließend fahrtindividuell getestet wird. Als Ergebnis wird der Durchschnitt der Metriken aller 20 Läufe ausgewertet, womit Schwankungen aufgrund der zufälligen Zusammensetzung der Testdatensätze herausgemittelt werden.

In den Diagrammen der Abbildung 8.5 wird das Ergebnis der Kreuzvalidierung im Rollwinkelfehler $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ gezeigt, wobei jeder Datenpunkt eine Messfahrt repräsentiert. Auf der x-Achse der Diagramme ist jeweils der gemittelte absolute Fehler und auf der y-Achse die relative Reduktion des Fehlers durch das Vollmodell gegenüber dem SB ($\varphi_i = \varphi(t_0)$) dargestellt. Die fahrtindividuellen Ergebnisse sind sowohl für alle Fahrsituationen (Abbildung 8.5a) als auch für einzelne MS (Abbildung 8.5b bis e) aufgeführt. Als Besonderheit zeigen sternförmige Datenpunkte die Prädiktionsgüte für eine Messfahrt, wenn diese mit keinem einzigen Sample in den Trainingsdaten abgebildet ist. Dies wurde für eine der mehrfachen Fahrten des Fahrers mit den dreieckig-grünen Datenpunkten in allen 20 Läufen der Kreuzvalidierung getestet (grüner Stern); die Fahrten von zwei weiteren Fahrern waren in 10 Läufen im Training vertreten (fünfeckige Datenpunkte in orange & gelb) und in den übrigen 10 Läufen nicht (orange & gelbe Sterne).

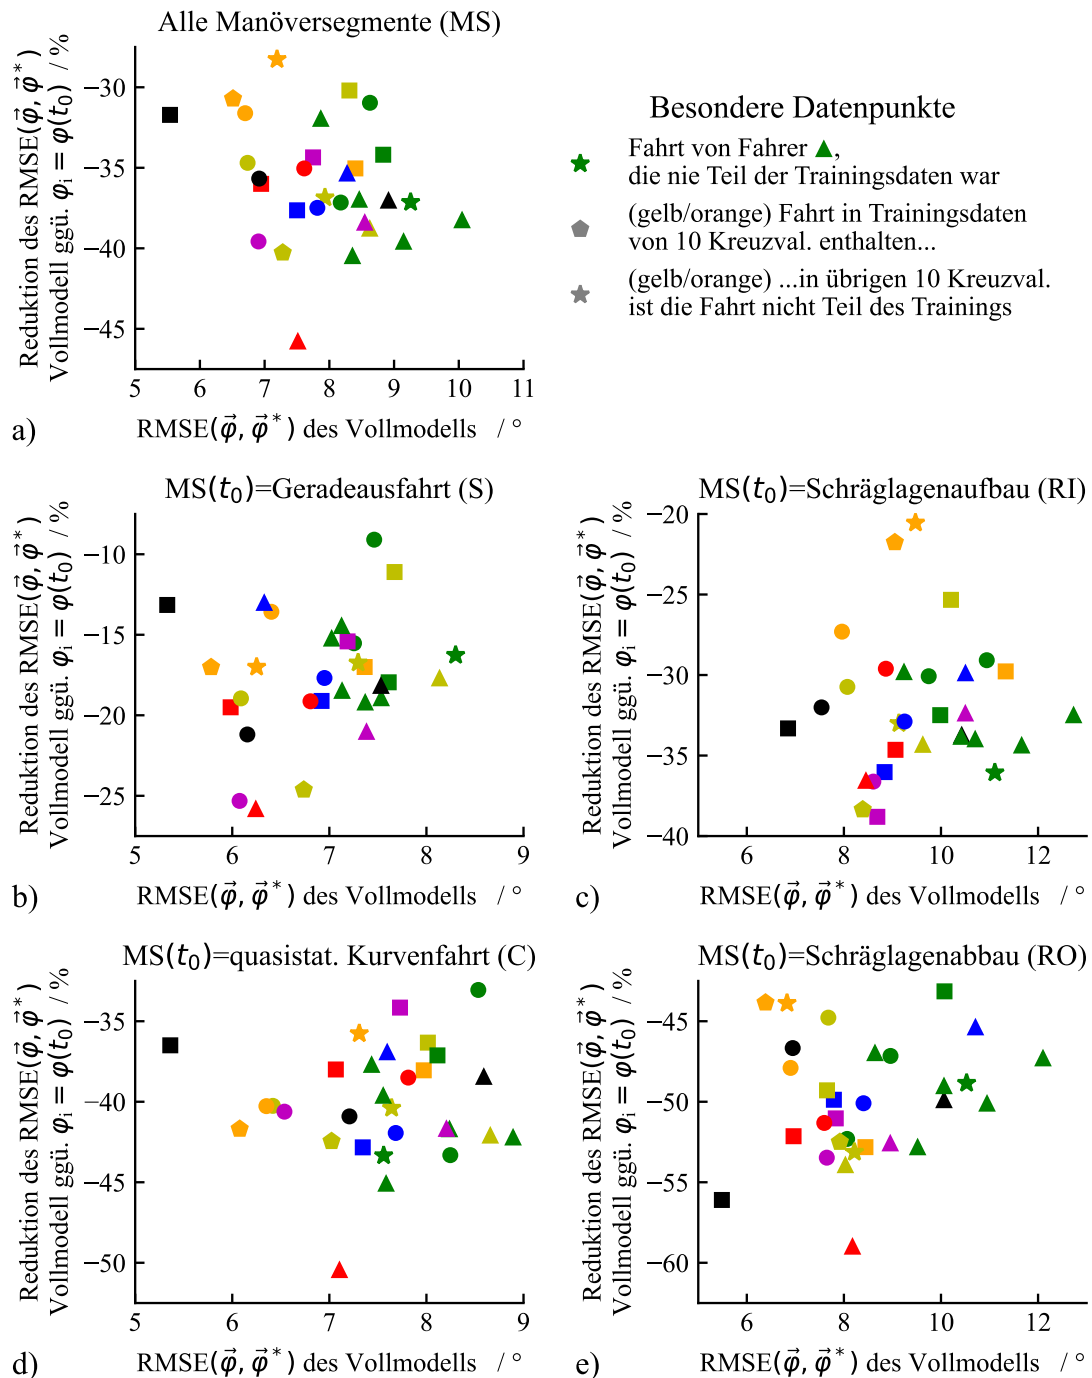


Abbildung 8.5: Fahrer- & fahrtspezifischer Gesamt-RMSE des Rollwinkels, gemittelt aus 20 Läufen der Kreuzvalidierungen: a) in allen Manöversegmente (MS), b) bis e) in bestimmten MS.

Abbildung 8.5a zeigt die Prädiktionsgüte des Vollmodells, ausgewertet in allen Fahrsituationen. Sie variiert stark von 5,5 bis 10° in den absoluten Werten des $\text{RMSE}(\vec{\varphi}, \vec{\varphi}^*)$. Aber auch in der relativen Verbesserung gegenüber dem SB besteht eine deutliche Streuung von -28 bis -46 % Reduktion. Es kann keine Korrelation zwischen relativer Reduktion und absolutem Fehler festgestellt werden.

Der Vergleich von fünfeckigen und sternförmigen Markern gleicher Farbe (gelb & orange) in Abbildung 8.5a ergibt, dass die Reduktion des Rollwinkelfehlers über alle Fahrsituationen um 3,4 % (gelb) bzw. 2,4 % (orange) schwächer ausfällt, wenn ein Fahrer – und damit seine

Fahrweise und sein Fahrstil – nicht in den Trainingsdaten vertreten ist. Bei der Betrachtung des Effekts in den einzelnen MS fällt auf, dass für den Schräglagenabbau – im Gegensatz zu den anderen MS – kein Unterschied vorhanden ist. Dies spricht dafür, dass sich die Fahrer bzgl. ihrer Rollwinkeltrajektorie in diesem MS ähnlich verhalten.

Die relativen Verbesserungen von $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ streuen für die wiederholten Fahrten des Fahrers mit den dreieckig-grünen Datenpunkten zwischen -32 und -40 % für alle MS. Dies macht deutlich, dass die Streckencharakteristik nicht nur den absoluten Fehler, sondern auch die relative Verbesserung gegenüber dem SB beeinflusst. Die als reine Testfahrt behandelte Fahrt des gleichen Fahrers, dargestellt als grüner Stern in Abbildung 8.5a, zeigt kein auffällig schlechteres Verhalten. Werden wie in Abbildung 8.5c nur die Testsituationen mit dem MS Schräglagenaufbau (RI) zum aktuellen Zeitpunkt der Prädiktion betrachtet, so wird in der reinen Testfahrt sogar die größte Reduktion von $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ erreicht. Es liegt nahe, dass dem gelernten Modell Fahrweise und -stil des Fahrers aus seinen anderen Messfahrten bekannt sind. Alle fünf Diagramme in Abbildung 8.5 haben einen gleich großen y-Achsenbereich (Abstand minimaler zu maximaler Wert). Die Streuung der relativen Verbesserung von $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ ist demnach für alle gezeigten MS ähnlich, was insbesondere für MS Geradeausfahrt, in welchem die geringsten relativen Verbesserungen auftreten, unerwartet ist.

Der dreieckig-rote Datenpunkt eines Fahrers fällt in Abbildung 8.5a als deutlicher Ausreißer bzgl. einer hohen Reduktion des Rollwinkelfehlers auf; im Vergleich zum SB kann das Vollmodell seine Fahrerabsicht außerordentlich gut erkennen. Die MS-spezifische Betrachtung zeigt, dass in C und RO eine herausragende Reduktion von $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ vorhanden ist, während der Fahrer in S und RI unter den Besten ist. Der Abgleich mit der Auswertung von Fahrweise und -stil in Abschnitt 6.3 ergibt, dass dieser Fahrer in seiner Fahrweise defensiv ist. Er befindet sich im unteren Drittel bzgl. der Fläche des g-g-Diagramms und der maximalen Rolldynamik und fährt mit sehr wenig Oberkörperbewegung, d.h. im Fahrstil „Legen“. In Timing und Amplitude der Kopfdrehung (siehe Abschnitt 6.4) liegt er im Mittelfeld. Werden die genannten Charakteristika von Fahrweise und -stil oder Kopfdrehung systematisch der Prädiktionsgüte der Fahrer gegenübergestellt, ergibt sich jedoch keine eindeutige Korrelation einer Charakteristik mit der Verbesserung des $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ durch das Vollmodell. Für den dreieckig-rot dargestellten Fahrer verbleibt eine Besonderheit, die ursächlich für die auffallend gute Trajektorienprädiktion sein kann: er ist seine Hausstrecke gefahren und weist dabei eine ausgesprochen „saubere“ (wenige Korrekturen der Fahrlinie) Fahrweise auf, wenn der Verlauf seiner Fahrt manuell betrachtet wird.

Das Vollmodell erreicht für den Fahrer mit dem orangefarbenen Stern / Fünfeck im MS Schräglagenaufbau, dargestellt in Abbildung 8.5c, eine auffällig geringe relative Verbesserung

des $RMSE(\vec{\varphi}, \vec{\varphi}^*)$. Einen Erklärungsansatz hierfür liefert seine spezielle Fahrweise in der Rollodynamik, die sich in einem Ausreißer in Abbildung 6.8a widerspiegelt: er zeigt eine auffallend hohe maximale Rollrate in Relation zu einem vergleichsweise geringen maximalen Rollwinkel. Ein ungewöhnliches Rollverhalten kann durch die RNN-basierte Rollwinkelprädiktion schlecht abgebildet werden, weil diese das durchschnittliche Verhalten erlernt. Auch im transienten MS des Schräglagenabbaus in Abbildung 8.5e kann das Vollmodell für diesen Fahrer nur eine vergleichsweise geringe Fehlerreduktion bewirken.

In Abschnitt 6.3 wurden zwei Fahrer mit außergewöhnlichem Fahrstil identifiziert: der Fahrer mit quadratisch-grünem Datenpunkt fährt im „Hängen“ und der mit quadratisch-gelbem Datenpunkt im „Hanging-Off“. Ersterer erreicht im MS Schräglagenabbau die geringste Reduktion des $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ aller Fahrer, während für Letzteren in den MS Geradeausfahrt und Schräglagenaufbau vergleichsweise geringe Verbesserungen erreicht werden. Um hierbei eine Korrelation festzustellen, müssten mehr Fahrer mit diesen Fahrstilen untersucht werden. Es kann jedoch davon ausgegangen werden, dass jegliche Fahrstile, die vom überwiegenden Verhalten der Fahrer abweichen (also nicht „Legen“ oder leichtes „Drücken“ sind), der Prädiktionsgüte nicht zuträglich sind.

Von den fünf Fahrern, die in der Auswertung des Zeitverzugs zwischen Kopfdrehung und Gierrate in Abbildung 6.12a die höchsten Vorlaufzeiten besitzen, befinden sich vier unter den Top fünf Fahrern mit der höchsten Reduktion von $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ im MS des Schräglagenaufbaus. Es wird daher vermutet, dass das Vollmodell besonders in diesem MS von der Eingangsgröße des Kopfdrehwinkels profitieren kann, sofern die Fahrer weit vorausschauen und deshalb früh den Kopf bewegen. In Abschnitt 8.4.3 wird der Effekt dieser Eingangsgröße genauer untersucht. Schräglagenwechsel sind in einzelnen Fahrten zu wenig vorhanden, sodass keine sinnvolle alleinige Auswertung dieses MS möglich ist.

Zusammengefasst schwankt die relative Verbesserung der Rollwinkelprädiktion, die mit dem Vollmodell gegenüber dem SB erreicht wird, um etwa 10 % zwischen den verschiedenen Fahrern und auch zwischen mehreren Fahrten des gleichen Fahrers. Mit Ausreißern streut die relative Verbesserung sogar bis zu 20 %. Neben dem Einfluss der Streckencharakteristik werden auch spezielle Fahrweisen oder Fahrstile als ursächlich für die hohe Varianz angesehen. Ein einfacher Zusammenhang, z.B. je geringer die Fläche im g-g-Diagramm desto besser die Prädiktion des Vollmodells, kann jedoch nicht identifiziert werden. Wird einer der 21 Testfahrer vom Training des Prädiktionsmodells ausgeschlossen, dann fällt die vom Vollmodell erreichte Verbesserung gegenüber dem SB für diesen Fahrer um etwa 3 % geringer aus. In Abschnitt 8.6 wird der Einfluss der Größe des Datensatzes auf dieses Verhalten diskutiert.

8.4 Bedeutung der neuartigen Messgrößen

Sechs der 16 Eingangsgrößen des Prädiktionsmodells werden als neuartige Messgrößen bezeichnet, weil sie in aktuellen Serienmotorrädern nicht erfasst werden. Wie in Tabelle 7.3 in Abschnitt 7.3 gekennzeichnet, handelt es sich um die drei Messgrößen des Lenksystems Lenkwinkel δ , -rate $\dot{\delta}$ und -moment M_z , sowie die Messgrößen des Fahrerverhaltens in Oberkörperneigung φ_F , lateraler Versatz des Oberkörpers $y_{F,M5}$ und Kopfdrehwinkel ψ_H . Die Bedeutung der genannten Signale für die Güte der Prädiktion ist aufgrund der „Black Box“ Eigenschaft des NN nicht ersichtlich und wird deshalb mit Hilfe einer Ablationsstudie (siehe Abschnitt 3.2) gesondert untersucht.

Es werden Ablationsmodelle trainiert, bei denen die Eingangsgrößen von Interesse gezielt weggelassen oder hinzugefügt werden, um deren Einfluss auf die Prädiktionsgüte zu ermitteln. Hinter jedem folgend vorgestellten Ablationsmodell stehen drei Modelltrainings in gleicher Konfiguration, deren Ergebnisse gemittelt werden, um eine statistische Sicherheit zu erhalten.

8.4.1 Effekt der Signalgruppen der Lenk- und Fahrerverhaltensgrößen

Zuerst wird untersucht, welchen Effekt die Entfernung der drei Lenkgrößen, der drei Fahrerverhaltensgrößen und die Kombination aus beidem hat. Letztere Variante wird als „Standardmodell“ (SM) bezeichnet, weil solch ein Prädiktionsmodell mit den aktuell auf Serienmotorrädern verfügbaren Messgrößen realisiert werden könnte.

Das Diagramm in Abbildung 8.6a zeigt die Verläufe des Rollwinkelfehlers $RMSE_i(\varphi_i, \varphi_i^*)$ über dem Prädiktionshorizont des Vollmodells und der drei Ablationsmodelle – keine Lenkgrößen, keine Fahrerverhaltensgrößen und SM. Im Diagramm rechts daneben in Abbildung 8.6b sind die Differenzverläufe $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ der drei Ablationsmodelle im Bezug zum Vollmodell dargestellt. An diesen kann die Bedeutung der Eingangsgrößen für die Rollwinkelprädiktion gut abgelesen werden. Alle drei Verläufe weisen eindeutig positive Werte auf, d.h. die Wegnahme von Eingangssignalen verursacht in allen drei Varianten einen erhöhten Rollwinkelfehler und damit eine niedrige Prädiktionsgüte.

Der orangefarbene Verlauf von $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ in Abbildung 8.6b zeigt, dass die Rollwinkelprädiktion ohne Lenkgrößen innerhalb der ersten Sekunde der Prädiktion einen Nachteil gegenüber dem Vollmodell aufbaut; mit zunehmender Prädiktionszeit nimmt die Differenz wieder langsam ab und für den maximalen Prädiktionshorizont wird der gleiche Rollwinkelfehler wie mit dem Vollmodell erreicht.

Die Tabelle in Abbildung 8.6d listet die relativen Veränderungen gegenüber dem Vollmodell in den Gesamtfehlern von Rollwinkel $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ und lateraler Position $RMSE(\vec{d}_{Lat})$ sowie

8.4 Bedeutung der neuartigen Messgrößen

in der Anzahl der Testsituationen mit besonders niedriger Vorausschauzeit $n(EI < 2 \text{ s})$ auf. Für das Ablationsmodell ohne Lenkgrößen besteht in diesen Metriken eine Verschlechterung um 1,1 %, 4,5 % und 16,3 %.

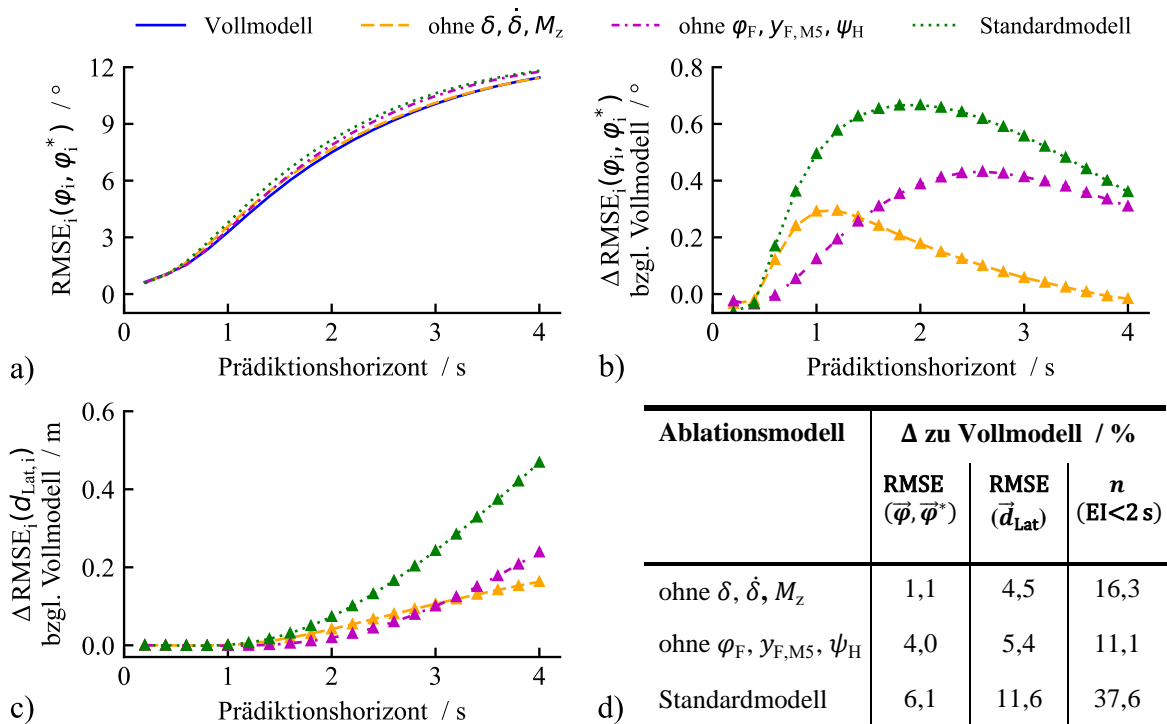


Abbildung 8.6: Prädiktionsgüte ohne Signale der Lenkung, des Fahrerhaltens und der Kombination aus beiden Varianten (Standardmodell). a) Verlauf des Rollwinkel-RMSE. Differenzverläufe von b) Rollwinkel-RMSE und c) lateralem Positions-RMSE bzgl. des Vollmodells. d) Relative Verschlechterung der Metriken im Vergleich zum Vollmodell.

Das Ablationsmodell ohne Fahrerhaltensgrößen zeigt mit 4,0 % eine deutlich stärkere Verschlechterung im Rollwinkelfehler $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ als das Modell ohne Lenkgrößen. Wie der pinkfarbene Differenzverlauf in Abbildung 8.6b erkennen lässt, wächst die Verschlechterung bzgl. des Vollmodells bis zu einer Prädiktionszeit von 2,6 s an, und klingt bis zum maximalen Prädiktionshorizont von 4 s nur noch leicht ab. Im lateralen Positionsfehler $RMSE(\vec{d}_{Lat})$ resultiert mit 5,4 % jedoch nur eine etwas größere Verschlechterung als für das Modell ohne Lenkgrößen. Dies liegt an der integrierenden Natur der Umrechnung von Rollwinkel- in Positionstrajektorie: wie Abbildung 8.6b zeigt, tritt die Verschlechterung in $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ bei Wegfall der Lenkgrößen früher auf dem Prädiktionshorizont auf und wirkt sich deshalb vergleichsweise stärker auf die Güte der Positionstrajektorien aus. Im Verlauf von $RMSE_i(d_{Lat,i})$ in Abbildung 8.6c ist zu sehen, dass sich erst für mehr als 3,2 s Prädiktionszeit größere laterale Positionsfehler für das Ablationsmodell ohne Fahrerhaltensgrößen ergeben. Aus diesem Grund fällt die Verschlechterung in der $n(EI < 2 \text{ s})$ -Metrik auch geringer aus als beim Wegfall der Lenkgrößen.

Die Rollwinkelprädiktion mit einem SM ohne Lenk- und ohne Fahrerverhaltensgrößen zeigt in den Differenzverläufen der Abbildung 8.6b und Abbildung 8.6c ein Verhalten, dass in etwa der Summe aus den beschriebenen getrennten Effekten entspricht (grüne Kurven). Die Reduktionen in $RMSE(\vec{\varphi}, \vec{\varphi}^*)$, $RMSE(\vec{d}_{Lat})$ und $n(EI < 2 \text{ s})$ betragen 6,1 %, 11,6 % und 37,6 %. Insbesondere in letzterer Metrik ist die Verschlechterung jedoch deutlich größer als die einzelnen Effekte der Signalgruppen. Demnach bestehen insbesondere in den schwierigen Testsituationen teilweise Redundanzen zwischen den Informationen der Lenk- und Fahrerverhaltensgrößen, weshalb erst der Wegfall aller neuen Messgrößen in einer deutlichen Verschlechterung resultiert.

8.4.2 Einzeleffekte der Lenkgrößen

Nachdem im vorherigen Abschnitt der Summeneffekt aller drei Lenkgrößen betrachtet wurde, sind im Folgenden die Einzeleffekte von δ , $\dot{\delta}$ und M_z beschrieben. Dem SM ohne neue Messgrößen werden sieben Ablationsmodelle mit allen Permutationen von einer, zwei und drei zusätzlichen Lenkgrößen gegenübergestellt, um die Relevanz der einzelnen Signale zu analysieren. In paarweisen Vergleichen wird sowohl die Differenz im Verlauf des Rollwinkelfehlers ($\Delta RMSE_i(\varphi_i, \varphi_i^*)$) als auch die relative Veränderung des Rollwinkelfehlers ($\Delta RMSE(\vec{\varphi}, \vec{\varphi}^*)$) in den einzelnen MS betrachtet.

Zunächst werden die Ablationsmodelle mit einer zusätzlichen Lenkgröße ($SM+\delta$, $SM+\dot{\delta}$, $SM+M_z$) in der matrixförmigen Darstellung in Abbildung 8.7 untereinander und gegenüber dem SM verglichen. Dabei wird jeweils das Ablationsmodell in der Zeile in Bezug zum Modell in der Spalte gesetzt (pink: Differenz Zeile minus Spalte, blau: Zeile relativ zur Spalte). Die hauptsächlichen Erkenntnisse aus dem Vergleich sind in Abbildung 8.7 mit Buchstaben markiert und im Folgenden erläutert.

- A) Alle drei Varianten einer zusätzlichen Lenkgröße erzielen gegenüber dem SM eine Reduktion des Rollwinkelfehlers über den gesamten Prädiktionshorizont. Dabei haben alle $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ -Verläufe ihr Minimum bei 1,2 s, d.h. innerhalb der Sekunde der Prädiktion wird der Vorteil gegenüber dem SM aufgebaut.
- B) Das Lenkmoment ($SM+M_z$) erzielt die größte Verbesserung der drei verglichenen Varianten (-1,7 % in $\Delta RMSE(\vec{\varphi}, \vec{\varphi}^*)$ über alle MS), danach folgen die Lenkrate ($SM+\dot{\delta}$, -1,1 %) und mit der geringsten Verbesserung der Lenkwinkel ($SM+\delta$, -0,8 %). Im MS quasistationäre Kurvenfahrt (C) bewirkt $SM+M_z$ die größte Verbesserung in $\Delta RMSE(\vec{\varphi}, \vec{\varphi}^*)$ gegenüber dem SM.

8.4 Bedeutung der neuartigen Messgrößen

- C) Die Variante $SM+M_z$ bewirkt insbesondere in quasistationärer Kurvenfahrt, Schräglagenabbau (RO) und -wechsel (RV) eine Reduktion des Fehlers gegenüber den Ablationsmodellen $SM+\delta$ und $SM+\dot{\delta}$.
- D) Der Schräglagenaufbau (RI) ist das einzige MS, in dem die Variante $SM+\dot{\delta}$ der Variante $SM+M_z$ überlegen ist.

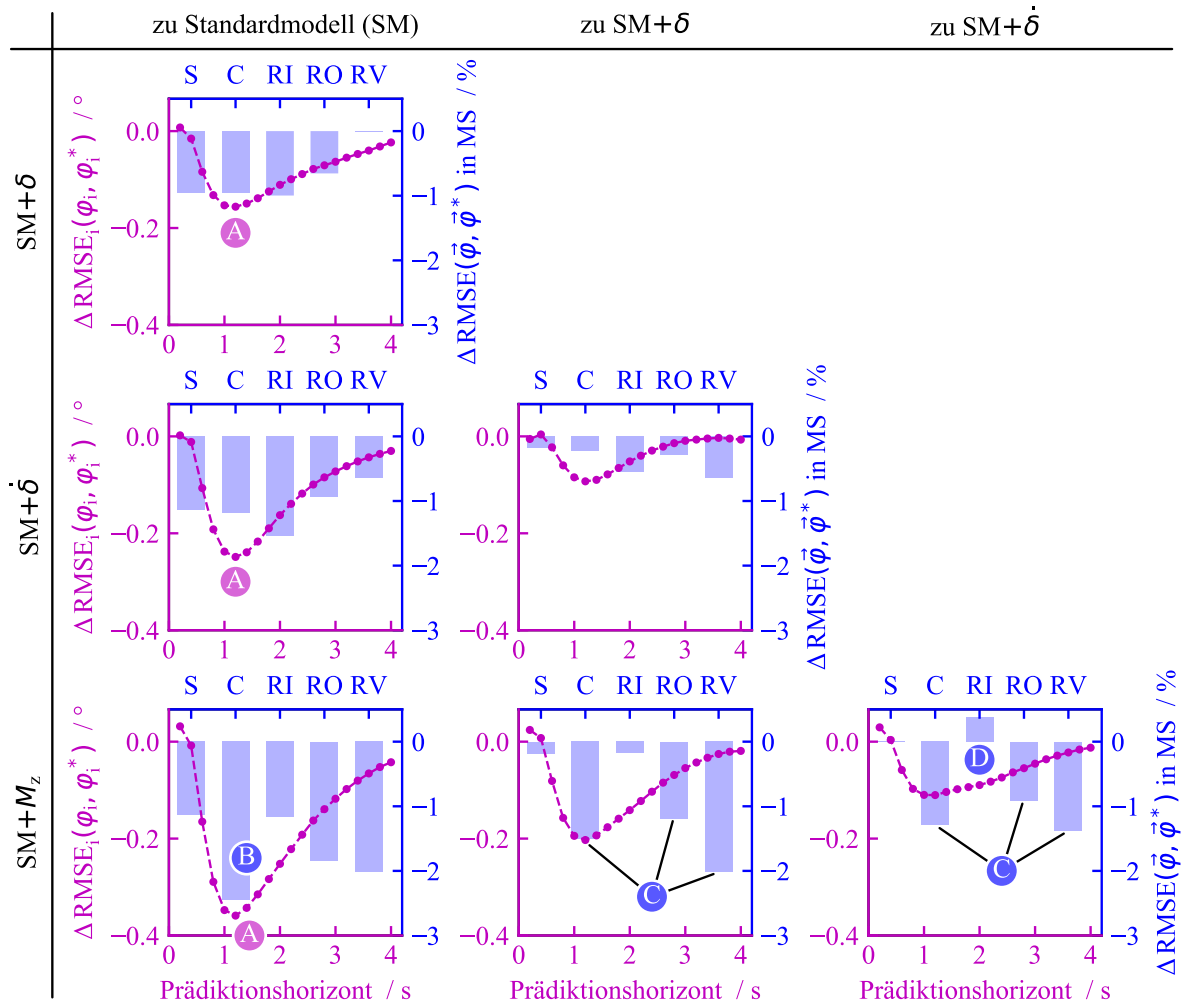


Abbildung 8.7: Ablationsmatrix zum Effekt einer zusätzlichen Lenkgröße als Eingangssignal.

Lenkwinkel und -rate sind physikalisch stark verwandte Signale, weshalb ein ähnlicher Effekt auf die Prädiktionsgüte zu erwarten war. Dass die Verbesserung durch $\dot{\delta}$ höher ausfällt als durch δ lässt sich mit dem Nacheilen des Winkels gegenüber der Rate erklären. Die Überprüfung des Verhaltens ist dennoch aufschlussreich, weil beide Größen in der Praxis mit unterschiedlichen Messprinzipien erfasst werden (siehe Abschnitt 4.2) und deshalb auch unterschiedliche Signalcharakteristiken vorliegen. So ist die Messung von $\dot{\delta}$ deutlich stärker von Störungen, z.B. durch Straßenanregungen oder Motorvibrationen beeinflusst.

In einem zweiten Schritt werden alle Ablationsmodelle mit zwei zusätzlichen Eingangsgrößen der Lenkung betrachtet. Die paarweisen Vergleiche untereinander und mit dem SM sind wie

zuvor in Form einer Matrix in Abbildung 8.8 dargestellt (Zeile in Bezug zur Spalte). Die Kombination von Lenkmoment und -winkel ($SM+\delta+M_z$) erreicht die höchste Reduktion des Rollwinkelfehlers. Außerdem sind die folgenden Beobachtungen in Abbildung 8.8 markiert.

- E) Alle Kombinationen zweier Lenkgrößen erreichen die maximale Reduktion $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ gegenüber dem SM bis zur Prädiktionszeit von 1,2 s – analog zum Verhalten der Ablationsmodelle mit einer zusätzlichen Lenkgröße.
- F) Alle Kombinationen zweier Lenkgrößen zeigen die höchsten relativen Verbesserungen gegenüber dem SM in den MS quasistationäre Kurvenfahrt und Schräglagenabbau.
- G) Im Vergleich zum Ablationsmodell $SM+\delta+\dot{\delta}$ führt die Verwendung des Lenkmoments (in $SM+\dot{\delta}+M_z$ und $SM+\delta+M_z$) besonders im MS quasistationäre Kurvenfahrt zur Reduktion des Rollwinkelfehlers.
- H) Ob der Lenkwinkel oder die Lenkrate mit dem Lenkmoment kombiniert wird ($SM+\dot{\delta}+M_z$ oder $SM+\delta+M_z$), macht nur einen geringen Unterschied im Verlauf und manöverspezifischen Verhalten des Rollwinkelfehlers.

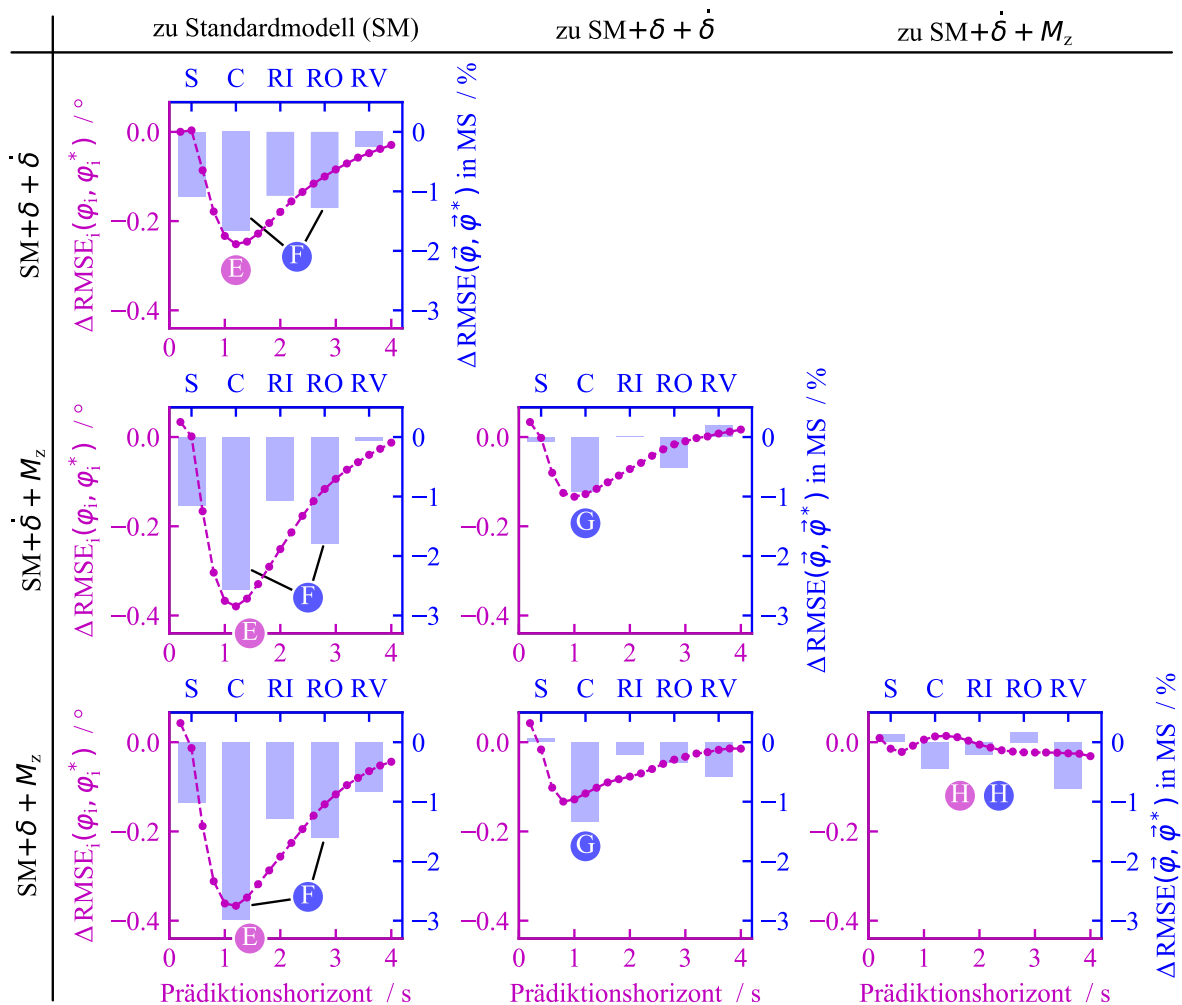


Abbildung 8.8: Ablationsmatrix zum Effekt von zwei Eingangsgrößen der Lenkung.

8.4 Bedeutung der neuartigen Messgrößen

Der $\Delta\text{RMSE}_i(\varphi_i, \varphi_i^*)$ -Verlauf und die Reduktion $\Delta\text{RMSE}(\vec{\varphi}, \vec{\varphi}^*)$ über alle MS von -1,2 % der Variante $\text{SM}+\delta+\dot{\delta}$ sind nahezu identisch mit dem Ablationsmodell $\text{SM}+\dot{\delta}$ aus Abbildung 8.7. Demnach sind die Informationen in Lenkwinkel und -rate – wie erwartet – stark redundant und die Nutzung beider führt nicht zu einer signifikanten Verbesserung.

Zuletzt werden die besten Ablationsmodelle mit einer und zwei Lenkgrößen, $\text{SM}+M_z$ und $\text{SM}+\delta+M_z$ aus den Vergleichen in Abbildung 8.7 und Abbildung 8.8, einem Prädiktionsmodell mit allen drei Eingangsgrößen der Lenkung ($\text{SM}+\delta+\dot{\delta}+M_z$) gegenübergestellt. In Abbildung 8.9 ist der matrixförmige Vergleich (Zeile in Bezug zur Spalte) der drei Ablationsmodelle dargestellt, wobei die folgenden Beobachtungen hervorgehoben sind.

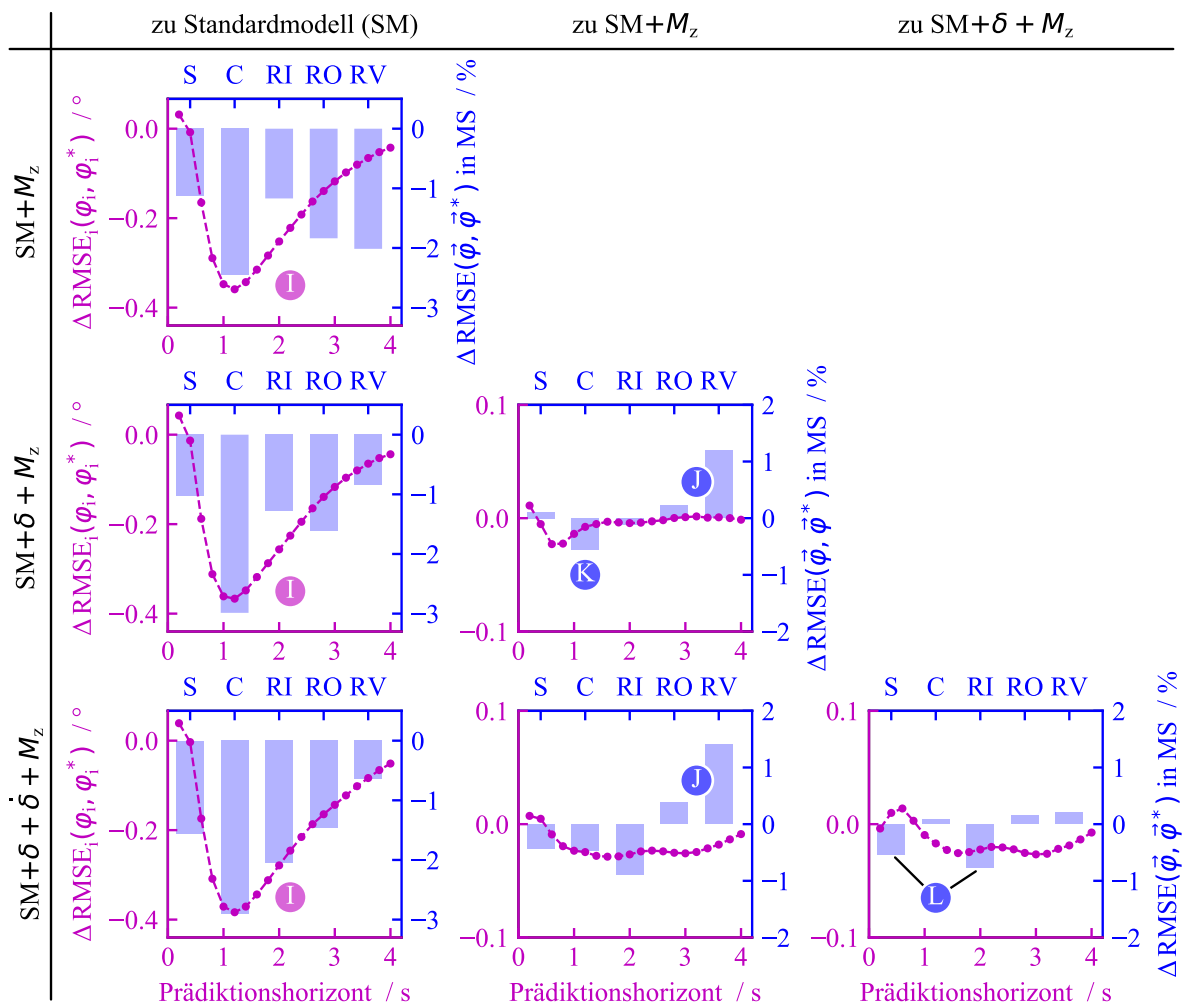


Abbildung 8.9: Beste Ablationsmodelle mit einer & zwei Eingangsgrößen der Lenkung verglichen mit Standardmodell und allen drei Lenkgrößen im Eingang.

- I) Die Ablationsmodelle $\text{SM}+M_z$, $\text{SM}+\delta+M_z$ und $\text{SM}+\delta+\dot{\delta}+M_z$ weisen nahezu identische $\Delta\text{RMSE}_i(\varphi_i, \varphi_i^*)$ -Verläufe im Bezug zum SM auf. Mit geringem Abstand erreicht die Variante mit allen drei Lenkgrößen die höchste Verbesserung von -2,0 % in

$\Delta\text{RMSE}(\vec{\varphi}, \vec{\varphi}^*)$ über alle MS. Dies bekräftigt die zentrale Bedeutung des Lenkmoments M_z für die Reduktion des Rollwinkelfehlers.

- J) Die alleinige Verwendung des Lenkmoments im Ablationsmodell $\text{SM}+M_z$ führt zur besten Prädiktionsgüte in den MS Schräglagenwechsel und -abbau.
- K) Die Hinzunahme des Lenkwinkels zum Lenkmoment in der Variante $\text{SM}+\delta+M_z$ bewirkt eine geringfügige Verbesserung der Rollwinkelprädiktion im MS quasistationäre Kurvenfahrt.
- L) Die Ergänzung der Lenkrate zu δ und M_z in der Variante $\text{SM}+\delta+\dot{\delta}+M_z$ resultiert in der Reduktion des Rollwinkelfehlers in den MS Geradeausfahrt (S) und Schräglagenaufbau.

Zusammengefasst bestätigt die detaillierte Betrachtung der Einzeleffekte der Lenkgrößen die herausragende Bedeutung des Lenkmoments, der primären querdynamischen Eingangsgröße des Motorrads, für die laterale Trajektorienprädiktion. Die Verläufe der Differenzen des Rollwinkelfehlers in den Ablationsversuchen zeigen, dass M_z für den Großteil der Steigerung der Prädiktionsgüte verantwortlich ist. Das RNN basierte Prädiktionsmodell, welches ungefilterte Rohsignale verarbeitet, scheint mit den vielfältigen Störungen in M_z umgehen zu können. Die Zustandsgrößen des Lenksystems δ und $\dot{\delta}$ bewirken hingegen nur geringfügige Steigerungen der Prädiktionsgüte. Bis zu einer Vorausschauzeit von 1,2 s sind Informationen der Fahrerabsicht, die zur Verbesserung der Rollwinkelprädiktion beitragen, in den Lenkgrößen enthalten.

8.4.3 Einzeleffekte der Fahrerverhaltensgrößen

Analog zu den Lenkgrößen werden auch die drei Fahrerverhaltensgrößen φ_F , $y_{F,M5}$ und ψ_H auf ihre individuelle Bedeutung für die Rollwinkelprädiktion hin untersucht. Zuerst werden dazu die drei Ablationsmodelle mit einer zusätzlichen Messgröße des Fahrerverhaltens mit dem SM verglichen. In Abbildung 8.10 sind die Differenzverläufe $\Delta\text{RMSE}_i(\varphi_i, \varphi_i^*)$ und die relative Verbesserung des Rollwinkelfehlers $\Delta\text{RMSE}(\vec{\varphi}, \vec{\varphi}^*)$ in den einzelnen MS dargestellt; die Vergleiche sind hierbei von den Spalten im Bezug zur Zeile zu lesen. Die im Folgenden beschriebenen Ergebnisse sind in Abbildung 8.10 markiert.

- M) Das Ablationsmodell $\text{SM}+y_{F,M5}$ zeigt, dass die alleinige Information über den lateralen Versatz des Fahreroberkörpers nahe dem Sitzpunkt keine Verbesserung der Rollwinkelprädiktion bewirkt. In den MS quasistationäre Kurvenfahrt, Schräglagenabbau und Schräglagenwechsel besteht sogar eine geringfügige Erhöhung des Fehlers. Eine

8.4 Bedeutung der neuartigen Messgrößen

Eingangsgröße ohne nützliche Information bzgl. der querdynamischen Fahrerabsicht kann das RNN-basierte Prädiktionsmodell demnach auch verschlechtern.

- N) Die Information der Oberkörperneigung des Fahrers ($SM+\varphi_F$) führt zu einer leicht verbesserten Rollwinkelprädiktion, wobei der Vorteil gegenüber dem SM bis zur Prädiktionszeit von 1,5 s aufgebaut wird.
- O) Das Messsignal des Kopfdrehwinkels ($SM+\psi_H$) bewirkt die mit Abstand deutlichste Verbesserung der Prädiktion. Die Reduktion des Rollwinkelfehlers findet besonders im Bereich zwischen 0,8 s und 2,2 s auf dem Prädiktionshorizont statt und erreicht ihr Maximum auf einem breiten Plateau bei etwa 3 s.
- P) Am höchsten fällt die relative Verbesserung $\Delta RMSE(\vec{\varphi}, \vec{\varphi}^*)$ des Ablationsmodells $SM+\psi_H$ mit fast -4 % im MS Schräglagenaufbau aus, gefolgt von quasistationärer Kurvenfahrt und Geradeausfahrt mit jeweils mehr als -3 % Reduktion. Dies bestätigt den in Abschnitt 8.3 formulierten positiven Effekt des Kopfdrehwinkels im Schräglagenaufbau.




Abbildung 8.10: Effekt einer zusätzlichen Eingangsgröße des Fahrerverhaltens.

Weiterhin werden die drei möglichen Permutationen von zwei Messgrößen des Fahrerverhaltens betrachtet. In der matrixförmigen Darstellung in Abbildung 8.11 sind die Varianten $SM+y_{F,M5}+\varphi_F$, $SM+y_{F,M5}+\psi_H$ und $SM+\varphi_F+\psi_H$ mit dem SM und der besten Variante aus der vorherigen Variation $SM+\psi_H$ verglichen (Spalte im Bezug zur Zeile). Hervorgehoben sind darin die folgend beschriebenen Ergebnisse.

- Q) Das Ablationsmodell $SM+y_{F,M5}+\varphi_F$ baut gegenüber dem SM in den ersten 1,5 s der Prädiktionszeit einen Vorteil auf. Der Verlauf von $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ verhält sich damit in Timing und Höhe annähernd wie die Variante $SM+\varphi_F$ aus Abbildung 8.10, d.h. die Kombination beider Signale der Oberkörperposition zeigt keine Synergieeffekte.

- R) Die Hinzunahme des lateralen Versatzes $y_{F,M5}$ zur Messgröße des Kopfdrehwinkels ψ_H im Ablationsmodell $SM+y_{F,M5}+\psi_H$ bewirkt gegenüber der Variante $SM+\psi_H$ eine geringe Verbesserung, die hauptsächlich im MS der Geradeausfahrt auftritt.
- S) Die Kombination von Oberkörperneigungswinkel φ_F und ψ_H ($SM+\varphi_F+\psi_H$) führt zur stärksten bisher beobachteten Reduktion des Rollwinkelfehlers gegenüber dem SM. Die Verbesserung baut sich bis zur Prädiktionszeit von 2,3 s auf und beträgt in allen MS mindestens 3 %.
- T) Wie der Vergleich zur Variante $SM+\psi_H$ zeigt, führt die Hinzunahme von φ_F im Ablationsmodell $SM+\varphi_F+\psi_H$ bis zur Prädiktionszeit von 1,6 s eine deutliche Verringerung des Rollwinkelfehlers herbei. Dabei tritt die Verbesserung der Prädiktionsgüte durch die Oberkörperneigung besonders in den MS Schräglagenabbau und -wechsel auf.

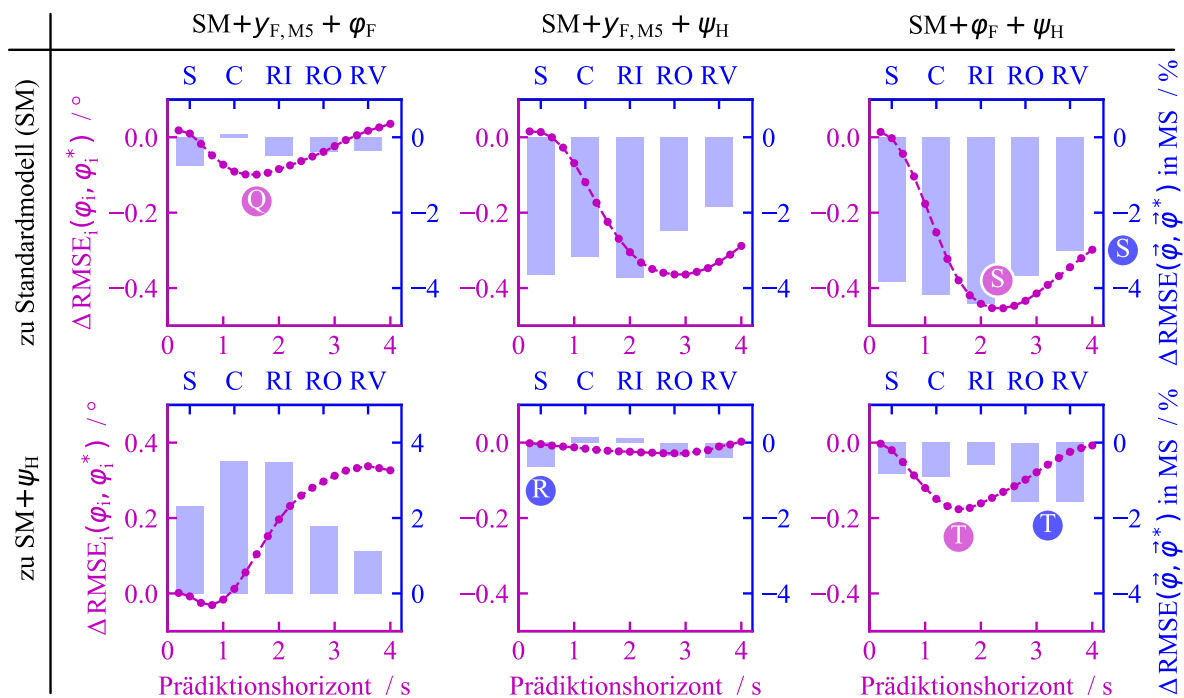


Abbildung 8.11: Ablationsmatrix zum Effekt zweier zusätzlicher Messgrößen des Fahrerverhaltens.

Es ist hervorzuheben, dass die Verbesserung, welche die Fahrerverhaltensgröße der Oberkörperneigung φ_F im Ablationsmodell $SM+\varphi_F+\psi_H$ gegenüber der Variante $SM+\psi_H$ erzeugt, größer ist als der alleinige Effekte von φ_F in der Variante $SM+\varphi_F$; vergleiche dazu die Markierungen „N“ in Abbildung 8.10 und „T“ in Abbildung 8.11. Insbesondere in den MS Schräglagenabbau und -wechsel besteht demnach ein Synergieeffekt zwischen φ_F und ψ_H .

Abschließend wird ein Ablationsmodell mit allen drei Messgrößen des Fahrerverhaltens ($SM+y_{F,M5}+\varphi_F+\psi_H$) mit dem SM und den besten Varianten mit einer und zwei zusätzlichen

8.4 Bedeutung der neuartigen Messgrößen

Fahrerverhaltensgrößen, $SM+\psi_H$ und $SM+\varphi_F+\psi_H$, verglichen. Die in Abbildung 8.12 dargestellten Gegenüberstellungen (Zeile im Bezug zur Spalte) liefern die markierten, folgend beschriebenen Ergebnisse.

- U) Die Nutzung aller drei Fahrerverhaltensgrößen als Eingänge der Rollwinkelprädiktion im Ablationsmodell $SM+\gamma_{F,M5}+\varphi_F+\psi_H$ bewirkt zur Prädiktionszeit von 2,5 s den Aufbau des größten bisher beobachteten Vorteils im Rollwinkelfehler im Vergleich zum SM.
- V) Die Variante $SM+\gamma_{F,M5}+\varphi_F+\psi_H$ erreicht eine Fehlerreduktion $\Delta RMSE(\vec{\varphi}, \vec{\varphi}^*)$ gegenüber dem SM von -3,7 % im MS Schräglagenabbau und mehr als -4 % in allen anderen MS.
- W) Gegenüber der alleinigen Nutzung des Kopfdrehwinkels ($SM+\psi_H$) wird durch die Hinzunahme der Fahreroberkörperposition ($\gamma_{F,M5}$ & φ_F) eine Verbesserung der Prädiktionsgüte in allen MS erreicht; sie tritt besonders im MS Schräglagenwechsel und auch in der Geradeausfahrt auf. Wie bereits in Anmerkung „T“ zur Abbildung 8.11 festgestellt, baut sich diese Verbesserung bis zur Prädiktionszeit von 1,6 s auf.
- X) Der Vergleich des Ablationsmodells mit allen drei Fahrerverhaltensgrößen und der Variante $SM+\varphi_F+\psi_H$ zeigt, dass die Berücksichtigung von $\gamma_{F,M5}$ über beinahe den gesamten Prädiktionshorizont eine Abnahme von $\Delta RMSE_i(\varphi_i, \varphi_i^*)$ bewirkt. Die Verbesserung der Rollwinkelprädiktion tritt insbesondere in den MS Schräglagenwechsel und Geradeausfahrt auf.




Abbildung 8.12: Rollwinkelprädiktion mit allen drei Fahrerverhaltensgrößen im Vergleich zum Standardmodell und den besten Ablationsmodellen mit einer & zwei Eingangsgrößen des Fahrerverhaltens.

Die detaillierte Ablationsstudie zu den einzelnen Effekten der Messgrößen des Fahrerverhaltens zeigt, dass die Information der Kopfdrehung den stärksten positiven Effekt auf die Güte der Fahrerabsichtserkennung besitzt; sie allein bewirkt im Vergleich zum SM eine Reduktion des $RMSE(\vec{\varphi}, \vec{\varphi}^*)$ von -3.0 %. Die zusätzliche Verwendung der Information zur lateralen Position des Fahreroberkörpers resultiert in einer Reduktion von insgesamt -4,7 % in Relation zum SM.

Dabei enthalten die Fahrerverhaltensgrößen bis zu einer Prädiktionszeit von 2,5 s Informationen zur Verbesserung der Rollwinkelprädiktion, was vor allem durch die Messgröße der Kopfdrehung bewirkt wird.

8.5 Einfluss der Längsdynamik

Mit der Vorhersage einer Rollwinkeltrajektorie wurde in Abschnitt 7.1 bewusst ein Prädiktionsansatz ausgewählt, der nur die laterale Komponente der Trajektorienprädiktion beschreibt. In der realen, primären Fahrtätigkeit der Bahnführung sind die Längs- und Querdynamik ohne Zweifel aneinandergelockt; der Motorradfahrer muss gleichzeitig Geschwindigkeits- und Rollwinkeltrajektorie planen, um erfolgreich eine Fahrlinie einzustellen. In diesem Abschnitt wird überprüft, inwiefern die bisher betrachteten Metriken der Positionsebene (eingeführt in Abschnitt 7.2) durch die Annahme der Längsdynamik beeinflusst werden. Außerdem werden Experimente zur Prädiktion der Längsdynamik durchgeführt, um das Potential einer erweiterten Trajektorienprädiktion abzuschätzen.

Für die Umrechnung der Rollwinkelprädiktion in eine relative Positionstrajektorie wurde bisher – wie in Abschnitt 7.2 beschrieben – die einfache Annahme der konstanten Fortschreibung der aktuellen Geschwindigkeit $v_x(t_0)$ gewählt. In einer erneuten Auswertung des Testdatensatzes wird der komplette Gegensatz abgeprüft, indem die Umrechnung mit den realen zukünftigen Geschwindigkeiten v_x^* erfolgt. Diese ideale – und gleichzeitig unrealistische – Annahme zeigt den Einfluss der Längsdynamik auf die Metriken in der Positionsebene.

In Tabelle 8.2 sind der laterale Positionsfehler $\text{RMSE}(\vec{d}_{\text{Lat}})$, Mittelwert des Evaluationsindex $\overline{\text{EI}}$ und Anteil der Testsamples mit EI kleiner 2 s $n(\text{EI} < 2 \text{ s})$ aufgeführt. Neu hinzu kommt die Angabe des longitudinalen Positionsfehlers $\text{RMSE}(\vec{d}_{\text{Lon}})$. Für jede Metrik ist auch die relative Veränderung Δ bzgl. dem bisherigen Ansatz der lateralen Trajektorienprädiktion dargestellt. Der Vergleich von erster und zweiter Zeile in Tabelle 8.2, das sind die bisherige und die ideale Geschwindigkeitsannahme in Kombination mit der Rollwinkelprädiktion des Vollmodells, zeigt, dass mit einer optimalen Längsdynamikannahme eine Verbesserung von -8,4 % in $\text{RMSE}(\vec{d}_{\text{Lat}})$ und sogar -30,6 % in $n(\text{EI} < 2 \text{ s})$ erreicht wird. Ursächlich für die Beeinflussung der lateralen Metriken bei Variation der Längsdynamik ist die Definition und damit Berechnung der Positionsfehler – die longitudinale und laterale Richtungskomponente des Fehlers bezieht sich auf die Orientierung (Gierwinkel) des Motorrads in jedem Prädiktionspunkt entlang der GT-Positionstrajektorie. Die gegenseitige Beeinflussung der lateralen und longitudinalen

8.5 Einfluss der Längsdynamik

Metriken wird andersherum auch daran deutlich, dass trotz der idealen Geschwindigkeitsannahme in der zweiten Zeile der Tabelle 8.2 ein $\text{RMSE}(\vec{d}_{\text{Lon}})$ von 0,54 m verbleibt.

Ansatz (längs- & querdynamisch)	$\text{RMSE}(\vec{d}_{\text{Lat}})$		$\text{RMSE}(\vec{d}_{\text{Lon}})$		$\overline{\text{EI}}$		$n(\text{EI} < 2 \text{ s})$	
	/ m	Δ / %	/ m	Δ / %	/ s	Δ / %	/ %	Δ / %
$v_x(t_0)$ konstant + Vollmodell	2,07	Ref.	3,36	Ref.	3,42	Ref.	1,35	Ref.
v_x^* (ideal) + Vollmodell	1,90	-8,4	0,54	-83,8	3,45	+0,7	0,94	-30,6
v_x-Prädiktion + Vollmodell	1,95	-6,0	2,13	-36,6	3,44	+0,6	0,95	-29,7
(v_x, φ) -Prädiktion	2,00	-3,4	2,30	-31,4	3,43	+0,3	1,00	-25,7
(x, y) -Prädiktion	2,04	-1,7	2,44	-27,5	3,39	-0,9	1,97	45,9

Tabelle 8.2: Metriken der Experimente zur längsdynamischen Trajektorienprädiktion.

Zur Bewertung des Potenzials einer ganzheitlichen Trajektorienprädiktion, welche einen manöverbasierten Modellansatz sowohl für die Querdynamik als auch für die Längsdynamik nutzt, werden drei Pilotexperimente durchgeführt. Für diese wird das Konzept des optimierten RNN-Prädiktionsmodells übernommen, d.h. es wird jeweils mit den in Abschnitt 7.3 und 7.4 beschriebenen Eingangsgrößen, Architektur- und Trainings-HP ein Prädiktionsmodell trainiert. In einem ersten Experiment wird eine Geschwindigkeitsprädiktion erstellt, die gemeinsam mit den Rollwinkelprädiktionen des bestehenden Vollmodells getestet wird. Das zweite Experiment stellt die gleichzeitige Prädiktion einer Rollwinkel- und einer Geschwindigkeits-trajektorie durch ein gemeinsames RNN-Modell dar. Im dritten Experiment wird die direkte Prädiktion der relativen Positionstrajektorie (x, y) durchgeführt. Weil die Modelle des zweiten und dritten Experiments jeweils zwei Trajektorien gleichzeitig prädizieren, werden die Größen ihrer NN-Schichten verdoppelt.

In den unteren drei Zeilen der Tabelle 8.2 ist die Prädiktionsgüte der drei Pilotexperimente aufgeführt. Alle drei Ansätze der ganzheitlichen Trajektorienprädiktion zeigen eine Verringerung in $\text{RMSE}(\vec{d}_{\text{Lat}})$ gegenüber der isolierten lateralen Prädiktion mit konstanter Geschwindigkeitsannahme. Hierbei erzielt die Variante der separaten Geschwindigkeitsprädiktion mit -6 % Verbesserung das beste Ergebnis. Auch in den übrigen drei Metriken erreicht die getrennte Längs- und Querdynamikprädiktion die besten Werte. In $n(\text{EI} < 2 \text{ s})$ wird mit -29,7 % Verbesserung sogar annähernd das Ergebnis der idealen Geschwindigkeitsannahme erreicht. Die Geschwindigkeitsprädiktion mit dem bestehenden Konzept des RNN-Prädiktionsmodells ermöglicht also insbesondere in den schwierigen Testsituationen eine deutliche Steigerung der Prädiktionsgüte auf Positionsebene.

Von den zwei kombinierten Ansätzen der ganzheitlichen Trajektorienprädiktion zeigt die gemeinsame Rollwinkel- und Geschwindigkeitsprädiktion in einem RNN-Modell in allen

Metriken bessere Ergebnisse als die direkte Positionsprädiktion. Letztere führt im Vergleich zur rein lateralen Trajektorienprädiktion sogar zu einer deutlichen Verschlechterung in \overline{EI} und $n(EI < 2 \text{ s})$, wie in Tabelle 8.2 rot hervorgehoben ist. Außerdem weist die direkte Berechnung von relativen Positionstrajektorien das Problem unstetiger Prädiktionen auf. Dieses wirkt sich direkt negativ auf die Metriken aus, weil keine integrierend wirkende Umrechnung aus der Rollwinkel-/ Geschwindigkeitsdomäne erfolgt.

8.6 Beantwortung der Forschungsfragen & Diskussion

Die in den Abschnitten 8.1 bis 8.4 beschriebenen Auswertungen haben das Prädiktionsverhalten des Vollmodells aus diversen Gesichtspunkten untersucht und in Relation zur Güte eines SB eingeordnet. Ein Blick in den in Abschnitt 2.2 vorgestellten Stand der Forschung zeigt, dass hiermit die erste Untersuchung vorliegt, welche die Trajektorienprädiktion für Motorräder auf einem – hinsichtlich Strecken- und Fahrervielfalt – repräsentativen Fahrdatensatz (siehe Kapitel 6) aus dem öffentlichen Straßenverkehr untersucht. Basierend auf den Ergebnissen können die in Abschnitt 1.4 formulierten Forschungsfragen für den in Kapitel 7 entwickelten manöverbasierten Modellansatz beantwortet werden.

RQ1: Wie verhält sich ein motorradspezifischer Algorithmus zur lateralen Trajektorienprädiktion, der neuartige Informationen über die Zustandsgrößen der Lenkung und querdynamische Fahrereingaben verwendet, gegenüber einem Standardbewegungsmodell?

Die motorradspezifische laterale Trajektorienprädiktion, die mit der RNN-basierten Prädiktion einer Rollwinkeltrajektorie und anschließender Umrechnung in eine relative Positionstrajektorie realisiert ist (Vollmodell), weist gegenüber dem SB der konstanten Kurvenfahrt eine stark verbesserte Erkennung der querdynamischen Fahrerabsicht auf. Auf dem Testdatensatz, der 7 % aller Messfahrten enthält, wird der RMSE der lateralen Positionsabweichung entlang des 4 s langen Prädiktionshorizonts von 3,9 m auf 2,1 m annähernd halbiert. Dabei zeigt sich über den gesamten betrachteten Geschwindigkeitsbereich ($> 30 \text{ km/h}$) eine gleichbleibend hohe Steigerung der Prädiktionsgüte.

Die Ergebnisse der fahrt- und fahrerindividuellen Auswertung der Trajektorienprädiktion in Abschnitt 8.3 zeigen, dass für eine komplett unbekannte Fahrt und damit Strecke eines im Training – durch andere Messfahrten – vorkommenden Fahrers keine Verschlechterung der Prädiktionsgüte besteht. Es wird daher erwartet, dass auch für unbekannte, nicht im Modelltraining vertretene Motorradfahrer eine Trajektorienprädiktion mit der beschriebenen

Güte realisiert werden kann, wenn der Trainingsdatensatz ausreichend viele Fahrer enthält – denn damit steigt die Diversität des Fahrerverhaltens in den Daten (Fahrweisen und -stile). Mit den 21 Testfahrern des selbst erhobenen Fahrdatensatzes wird bereits erreicht, dass die Verbesserung des Vollmodells gegenüber dem SB nur um 3 % geringer ausfällt, wenn ein Fahrer nicht in den Trainingsdaten vertreten ist.

Die fahrt- und fahrerindividuelle Auswertung ergibt außerdem, dass die Verbesserung des Vollmodells gegenüber dem SB zwischen den Fahrten und damit auch den Fahrern um 10 % streut, mit der Berücksichtigung von Ausreißern sogar um bis zu 20 % (bzgl. des RMSE des Rollwinkels). Für die hohe Streuung der Prädiktionsgüte kann keine eindeutige Ursache identifiziert werden. Es bestehen sicher Streckeneinflüsse aufgrund der unterschiedlichen Routen der Messfahrten, doch zeigt auch eine MS-spezifische Analyse der Prädiktionsgüte, dass in den einzelnen MS Streuung in gleicher Größenordnung auftritt. Zwischen der Prädiktionsgüte und den unterschiedlichen Fahrweisen und Fahrstilen der Fahrer bestehen zahlreiche Wechselwirkungen, jedoch ist die Stichprobe in Anbetracht der hohen Anzahl an Einflussfaktoren für eine sinnvolle Korrelationsanalyse zu klein. Die Ergebnisse deuten darauf hin, dass ein runder Fahrstil mit wenigen lateralen Korrekturen besser prädiziert werden kann.

RQ2: Welche Vorausschauzeiten sind mit dem entwickelten Algorithmus in diversen Fahrsituationen erreichbar?

Zur Beantwortung dieser Frage wurde in jeder Testsituation die maximale Prädiktionszeit ausgewertet, für die der laterale Positionsfehler noch unterhalb von 2 m liegt (EI-Metrik). Mit dem Vollmodell wird erreicht, dass der EI in 98,6 % der Testsituationen mindestens 2 s beträgt. Das stellt eine deutliche Steigerung im Vergleich zum SB dar, welches dies nur in 87,5 % der Situationen gewährleisten kann. Wenn sich das Motorrad im aktuellen Fahrzustand der Geradeausfahrt oder in quasistationärer Kurvenfahrt befindet, dann wird sogar in mehr als 99 % der Situationen ein EI von mindestens 2 s erreicht. Eine Vorausschauzeit von mehr als 3 s realisiert das Vollmodell in 71,2 % aller Testsituationen (SB: 46,8 %).

Die manöverbasierte Fahrerabsichtserkennung in Gestalt der Rollwinkelprädiktion kann im Vergleich zum SB die größten Verbesserungen im transienten MS des Schräglagenabbaus erzielen; dort wird der RMSE des Rollwinkels um -55 % reduziert. Auch im Schräglagenwechsel und der quasistationären Kurvenfahrt betragen die Verbesserungen mehr als 40 %. Die Vorhersagen des Kurvenbeginns aus der Geradeausfahrt kommend und der Zielschräglage während des Schräglagenaufbaus stellen für das Vollmodell die größten Herausforderungen dar, doch auch hier werden -22 % und -37 % Verringerung des Rollwinkelfehlers gegenüber dem SB erzielt.

In Relation zur Bewertung des Stands der Technik der Trajektorienprädiktion von Motorrädern durch das CMC [22], welches für jegliche querdynamische Fahrmanöver eine minimale Vorausschauzeit zwischen 1 und 2 s und für Geradeausfahrt zwischen 2 und 3 s beschreibt, kann der entwickelte manöverbasierte Algorithmus eine signifikante Verbesserung der Trajektorienprädiktion in allen Fahrsituationen erreichen. In Situationen, in denen ein SB weniger als 2 s Vorausschauzeit besitzt, kann diese im Mittel um 1 s erhöht werden. In Anbetracht dessen lohnt sich eine erneute Bewertung, ob die verbesserte Trajektorienprädiktion eine erfolgreiche Kollisionswarnung im Rahmen von C-ITS Sicherheitsfunktionen ermöglicht.

RQ3: Welche Bedeutung haben die neuartigen Messgrößen des Fahrzustands in der Lenkung und querdynamischer Fahrereingaben für die Trajektorienprädiktion?

Bzgl. der querdynamischen Fahrereingaben in die Lenkung des Motorrads wurde die Relevanz der drei Messgrößen Lenkwinkel, -rate und -moment für die Prädiktionsgüte untersucht. Alle Drei führen auf den ersten 1,2 s des Prädiktionshorizonts eine Verbesserung der Rollwinkelprädiktion herbei, die sich deutlich in der Reduktion der Anzahl von Testsamples mit einem EI von weniger als 2 s niederschlägt – d.h. es wird besonders in schwierigen, transienten Fahrsituationen mit geringer Vorausschauzeit eine Verbesserung bewirkt. Von den drei Lenkgrößen hat das Lenkmoment mit Abstand die größte Bedeutung, obwohl es sich um ein Messsignal mit zahlreichen Störeinflüssen handelt; allein kann es den Rollwinkelfehler um -1,7 % reduzieren, während die Kombination aller drei Lenkgrößen eine -2,0 %ige Verbesserung im Vergleich zu einem SM ohne neuartige Messgrößen erzielt.

Die als Fahrerverhaltensgrößen bezeichneten Messgrößen der Oberkörperposition in Neigungswinkel und lateralem Versatz nahe des Sitzpunkts und des Kopfdrehwinkels bewirken gemeinsam eine -4,7 %ige Reduktion des Rollwinkelfehlers. Diese Verbesserung wird bis zur Prädiktionszeit von 2,5 s aufgebaut, womit der Informationsgehalt deutlich weiter in die Zukunft reicht als bei den Lenkgrößen. Dies wird besonders vom Signal des Kopfdrehwinkels verursacht, der die Vorhersage bis zu 3 s lang und mit -3,0 % von allen drei Messgrößen am stärksten verbessert. Für die Information der Oberkörperposition kann bis zur Prädiktionszeit von 1,5 s ein positiver Einfluss auf die Rollwinkelprädiktion ausgemacht werden. Trotz ihres größeren positiven Effekts im Rollwinkel- und lateralen Positionsfehler, haben die Fahrerverhaltensgrößen auf die Anzahl der Situationen mit einem EI von weniger als 2 s Situationen einen geringeren positiven Einfluss als die Lenkgrößen.

Die gemeinsame Verwendung von Lenk- und Fahrerverhaltensgrößen im Vollmodell zeigt, dass sich die einzelnen positiven Effekte aufsummieren. Bzgl. der Vorausschauzeit in besonders schwierigen Testsituationen zeigt sich sogar ein deutlicher Synergieeffekt. Die neuen

Messgrößen, insbesondere das Lenkmoment und der Kopfdrehwinkel, beinhalten demnach unterschiedliche und jeweils wichtige Informationen zur querdynamischen Fahrerabsicht. Ein RNN-basiertes Standardmodell ohne die neuen Messgrößen erreicht in 98,1 % der Testsituationen ein EI von mindestens 2 s und in 66,5 % mehr als 3 s.

Im Anschluss an die Zusammenfassung des Prädiktionsverhaltens im Rahmen der Beantwortung der Forschungsfragen werden folgend die Potenziale und Limitierungen des gewählten Ansatzes der lateralen Fahrerabsichtserkennung diskutiert.

Der Ansatz der Rollwinkelprädiktion ist nicht nur im Sinne der Fokussierung auf die Querdynamik zur zielgerichteten Beantwortung der Forschungsfragen valide, sondern erzielt im Vergleich zu anderen Ansätzen eine hohe Prädiktionsgüte. Dies wird in den Pilotexperimenten zur Prädiktion der Längsdynamik in Abschnitt 8.5 deutlich. In diesem werden kombinierte Modelle trainiert, welche die längs- und querdynamische Prädiktion in einem gemeinsamen Algorithmus – also einem gleichzeitig gelernten NN – vereinen, indem die optimierte Modellarchitektur der Rollwinkelprädiktion weitestgehend übernommen wird. Sowohl die kombinierte Rollwinkel- und Geschwindigkeitsprädiktion als auch die direkte Positionsprädiktion erzielen eine schlechtere Prädiktionsgüte im Vergleich zu getrennt optimierten Algorithmen der Rollwinkel- und Geschwindigkeitsprädiktion.

Die Auswertung zum Geschwindigkeitseinfluss in Abschnitt 8.5 zeigt außerdem, dass eine längsdynamische Fahrerabsichtserkennung auch in Bezug auf die laterale Prädiktionsgüte eine Verbesserung bewirken kann. Der RMSE des lateralen Positionsfehlers und die Anzahl der Testsamples mit einem EI kleiner 2 s können theoretisch um bis zu -8,4 % und -30,6 % reduziert werden, wenn der zukünftige Geschwindigkeitsverlauf bekannt wäre. Mit der Übernahme der optimierten Modellarchitektur aus Kapitel 7 wird eine prototypische Geschwindigkeitsprädiktion realisiert. Obwohl z.B. die Eingangsgrößen der Prädiktion für eine longitudinale Fahrerabsichtserkennung nicht ideal sind, werden in den genannten Metriken der lateralen Prädiktionsgüte bereits große Verbesserungen von -6,0 % bzw. -29,7 % erreicht.

Aus dem in Abschnitt 2.2 beschriebenen Stand der Forschung der manöver- oder interaktionsbasierten Fahrerabsichtserkennung ist bekannt, dass multimodale Ansätze häufig bessere Prädiktionen erreichen als die in dieser Arbeit verfolgte unimodale Prädiktion. Einfach ausgedrückt muss ein NN-Prädiktionsmodell weniger Kompromisse im Training eingehen, weil unterschiedliche Verhaltensweisen zu gegebenen Situationen erlernt werden können. So ist z.B. eine Multimodalität bzgl. unterschiedlicher Fahrweisen oder Fahrstile denkbar, wobei für beides deutlich mehr Daten, insbesondere von den aktuell unterrepräsentierten Fahrertypen,

notwendig wären. Auch die Multimodalität bzgl. der einzelnen MS oder auch daraus zusammengesetzter Manöver (z.B. einem Spurwechsel) ist denkbar, kann aber nur erfolgreich realisiert werden, wenn ein prädiktives Element zur Auswahl der Mode verfügbar ist – z.B. ein maschinell gelernter Prädiktor des zukünftigen Manövers. Dessen Realisierung ist besonders im Hinblick auf die ungleiche Verteilung bestimmter querdynamischer Fahrmanöver bzw. MS in den Realfahrdaten schwierig.

Aufgrund des messtechnischen Aufbaus des Versuchsmotorrads konnte die Erhebung der Realfahrdaten in dieser Arbeit nur mit einem Fahrzeug durchgeführt werden. Für Motorräder mit ähnlichen Fahreigenschaften, also Fahrzeuge mit ähnlicher Antriebsleistung, Gewicht und Geometrie, wird eine Übertragbarkeit des Algorithmus ohne signifikante Einbußen in der Prädiktionsgüte angenommen. Beispielsweise wird auch ein Wechsel des Reifentyps, der mit einem anderen quasistationären Lenkmomentverhalten einhergeht, als unproblematisch für die Prädiktionsgüte eingeschätzt; denn besonders aufgrund der zahlreichen Einflussfaktoren und Störungen, die auf das Lenkmomentverhalten einwirken, hat das RNN-basierte Prädiktionsmodell bereits eine Robustheit gegenüber gestörten und sich verändernden Systemverhalten gelernt. Für deutlich agilere bzw. trägere oder im maximalen Rollwinkel limitierte Motorräder – also alle Veränderungen, die eine signifikant andere Fahrweise des Fahrers in Kurvenfahrt bewirken – muss jedoch mit einer geringeren Prädiktionsgüte gerechnet werden.

Sofern eine deutliche Steigerung der Vorausschauzeiten der Trajektorienprädiktion über das aufgezeigte Potenzial hinaus notwendig ist, um bestimmte aktive Sicherheitssysteme zu realisieren, müssen einem Prädiktionsmodell weitere Informationsquellen zur Verfügung gestellt werden, die in dieser Arbeit nicht berücksichtigt sind. Hierfür kommen im Allgemeinen Karteninformation und Umfeldsensorik (Radar, Lidar, Kamera) in Frage.

Wie am Ende des Abschnitts 7.4 beschrieben ist, liegt mit 17396 Modellparametern ein vergleichsweise kleines RNN-basiertes Prädiktionsmodell vor. Bzgl. der Implementierung auf einem Steuergerät ist daher nicht mit Speicherproblemen zu rechnen. Jedoch muss aufgrund der rekurrenten Funktionsweise der LSTM-Schichten in jedem Zeitschritt eine gesamte Eingangszeitsequenz verarbeitet werden, womit zahlreiche sequenzielle Rechenoperationen einhergehen (vgl. Abschnitt 7.4). Im Hinblick auf eine echtzeitfähige Prädiktion könnte dies für aktuelle Steuergeräte eine zu hohe Anforderung darstellen. Stattdessen ist es während der Inferenz auf dem Motorrad sinnvoll, dass Rechenergebnisse aus vorherigen Zeitschritten wiederverwendet werden. Dies könnte mit der Änderung hin zu „stateful“ LSTM-Schichten realisiert werden [96]. Damit kann die Anzahl an Rechenoperationen je Zeitschritt theoretisch auf die Größenordnung der Anzahl der Modellparameter reduziert werden.

9 Zusammenfassung & Ausblick

Zukünftige aktive Sicherheitssysteme für Motorräder benötigen Trajektorienprädiktion, damit warnende und eingreifende Systeme kritische Fahrsituationen antizipieren und rechtzeitig reagieren können. Weil klassisch physikalische Bewegungsmodelle in Kurvenfahrt Prädiktionshorizonte von nur 1 bis maximal 2 s mit ausreichender Genauigkeit erreichen, wird die Entwicklung von motorradspezifischen Algorithmen der Trajektorienprädiktion angestrebt. Insbesondere in Kurvenfahrt unterscheidet sich die Fahrdynamik von PKW und Motorrad, weshalb diese Arbeit die laterale Trajektorienprädiktion fokussiert. In aktuellen Serienmotorrädern und ihren Assistenzsystemen werden keine Informationen zu den querdynamisch wirksamen Fahrereingaben verarbeitet. Dabei wird in den Signalen der Fahrereingabe in die Lenkung – dem Lenkmoment und den daraus folgenden Zustandsgrößen Lenkrate und -winkel – sowie der lateralen Schwerpunktverschiebung des Fahrers Potential für die Verbesserung der Trajektorienprädiktion gesehen.

Zur Untersuchung der neuartigen Messgrößen in der Lenkung und Oberkörperposition wurde ein Versuchsmotorrad mit prototypischer Messtechnik ausgestattet. Auf diesem werden das Lenkmoment – mit Dehnmessstreifen an der Lenkstange – und die Oberkörperposition des Fahrers in Neigungswinkel und lateralem Versatz am Sitzpunkt – mit am Fahrer angebrachten optischen Markern und einer Kamera – gemessen. Das kamerabasierte Messsystem, welches den Fahrer von hinten aufnimmt, ermöglicht außerdem die Messung der Kopfdrehung, indem zusätzliche Marker am Helm appliziert sind.

Mit dem Versuchsmotorrad wurden zunächst die definierten Fahrmanöver quasistationäre Kreisfahrt, Slalom und Spurwechsel auf abgeschlossener Teststrecke durchgeführt, um das Verhalten der neuen Messgrößen der Lenkung und des Fahrerverhaltens im Kontext des querdynamischen Übertragungsverhaltens zu bewerten. In stationärer Querdynamik wurde die Beeinflussung des Lenkmomentbedarfs und damit des Handlings sowohl durch verschiedene Fahrstile in der Oberkörperposition als auch durch weitere Umwelt- und Störeinflüsse wie die Straßenneigung, Seitenwind, Abnutzung der Reifen, Reifentemperatur, etc. beobachtet. In transientser Querdynamik bestätigten sich die Beobachtungen diverser Untersuchungen aus dem Stand der Forschung, dass das Lenkmoment als dominante und deshalb einzige Fahrereingangsgröße in transientser Querdynamik angesehen werden kann.

Ihre Oberkörperbewegung setzten die Testfahrer in allen absolvierten transienten Manövern reaktiv bzgl. der Fahrzeugbewegung ein, weshalb nicht von einer aktiven Eingabe für ein querdynamisches Fahrmanöver gesprochen werden kann. Die Fahrerposition wird deshalb als Messgröße des Fahrerhaltens bezeichnet. In den transienten Fahrmanövern eilt die Lenkmomenteingabe den ersten Reaktionen in den Zustandsgrößen um 0,1 bis 0,5 s voraus. Daraus ergibt sich nur ein geringer Zeitvorteil zur Erweiterung des Prädiktionshorizonts für eine physikalische Trajektorienprädiktion, wenn diese die Lenkmoment-Fahrereingabe berücksichtigt.

Basierend auf den Ergebnissen zum Übertragungsverhalten der neuen Messgrößen und ihrer Nutzung durch den Fahrer wurde sich gegen die Realisierung einer motorradspezifischen physikalischen Trajektorienprädiktion entschieden, weil die erwarteten Vorteile in Relation zur Komplexität der Querdynamikmodelle des Zweirads als zu gering eingeschätzt wurden. Stattdessen wurde ein manöverbasierter Algorithmus der Trajektorienprädiktion entwickelt, welcher Informationen zur Fahrerabsicht aus den neuen Messgrößen der Lenkung, des Fahrerhaltens und den übrigen/üblichen fahrdynamischen Zustandsgrößen extrahiert.

Für die manöverbasierte Trajektorienprädiktion wird ein maschinell gelerntes Prädiktionsmodell der Klasse der rekurrenten Neuronalen Netze (RNN) eingesetzt, die für die Interpretation von Zeitreihendaten besonders geeignet sind. Der zum Training eines NN-Modells mit hoher Prädiktionsgüte und Generalisierbarkeit benötigte ausführliche Fahrdatensatz wurde mit dem Versuchsmotorrad eigens erhoben, weil keine vergleichbaren Datensätze verfügbar sind. Für eine möglichst hohe Diversität wurden die 74 h Fahrzeit im öffentlichen Straßenverkehr von 21 Testfahrern auf unterschiedlichen Fahrstrecken absolviert. Im Sinne des Fokus auf die laterale Trajektorienprädiktion wurde eine unimodale Regression der zukünftigen Rollwinkeltrajektorie des Motorrads in einem NN-Modell mit LSTM (Long Short-Term Memory) Schicht realisiert. Letztere stellt die Eingangsschicht des Prädiktionsmodells dar und verarbeitet zeitdiskrete Sequenzen der Signalhistorie von 16 ungefilterten Eingangsgrößen. Das NN-Modell interpretiert aus diesen Informationen die Fahrerabsicht und schätzt über einen 4 s langen Prädiktionshorizont die zukünftigen Rollwinkel an 20 Stützstellen. Innerhalb eines definierten Parameterraums wurden die Hyperparameter des Prädiktionsmodells systematisch optimiert. Besonders hervorzuheben sind die Methoden der Differenzprädiktion und dualen Diskretisierung, die glatte Prädiktionen und eine bessere Interpretation der Eingangsgrößen ermöglichen.

Die rein laterale Rollwinkelprädiktion wird durch eine anschließende Transformation, bei der konstante Fahrzeuggeschwindigkeit angenommen wird, in eine relative Positionstrajektorie

überführt. Gegenüber dem Standardbewegungsmodell der konstant fortgeschriebenen Kurvenfahrt zeigt die maschinell gelernte laterale Trajektorienprädiktion große Verbesserungen. Der Gesamtfehler der lateralen Positionsabweichung wird über den 4 s langen Prädiktionshorizont um 46 % auf 2,1 m reduziert. Insbesondere wird aber die Anzahl an Testsituationen, in denen vormals weniger als 2 s Vorausschauzeit (limitiert durch einen maximal erlaubten lateralen Positionsfehler von 2 m) erreicht wurden, um 89 % auf einen Anteil von nur noch 1,4 % verringert. Dabei steigt der erreichbare Prädiktionshorizont in diesen Situationen im Mittel um 1 s.

Die Entwicklung eines Zustandsautomaten zur Klassifizierung der Querdynamik der Motorradfahrt in fünf richtungsunabhängige Manöversegmente erlaubt die systematische Auswertung der Prädiktionsgüte in verschiedenen Fahrsituationen. Die manöverbasierte Trajektorienprädiktion zeigt die größte Verbesserung im Vergleich zum Standardbewegungsmodell, wenn zum Zeitpunkt der Prädiktion ein Schräglagenabbau vorliegt. Dies liegt daran, dass in dieser Fahrsituation bzgl. der zukünftigen Fahrtrajektorie meist die vergleichsweise triviale Fahrerabsicht der Geradeausfahrt besteht.

Die Relevanz der neuen Messgrößen der Lenkung und des Fahrerverhaltens für die Güte der lateralen Trajektorienprädiktion wurde in detaillierten Ablationsstudien untersucht. Ein Modell ohne diese neuen Messgrößen, das mit den auf heutigen Serienmotorrädern verfügbaren Signalen realisiert werden könnte, besitzt einen um 11,6 % vergrößerten RMSE des lateralen Positionsfehlers, der Anteil der Testsituationen mit weniger als 2 s Vorausschauzeit steigt auf 1,9 %. Knapp die Hälfte der Verschlechterung in der lateralen Position geht auf den Verlust der Information der Lenkgrößen zurück, die innerhalb der ersten Sekunde der Rollwinkelprädiktion eine Verbesserung bewirken; dabei ist das Lenkmoment für den überwiegenden Anteil des positiven Effekts verantwortlich, Lenkwinkel und -rate tragen nur wenig zur verbesserten Prädiktion bei. Die andere Hälfte der Verschlechterung im RMSE der lateralen Position wird vom Verlust der Information der Oberkörperposition und des Kopfdrehwinkels bewirkt. Der Neigungswinkel und laterale Versatz des Fahreroberkörpers besitzen bis zur Prädiktionszeit von 1,5 s einen positiven Einfluss auf die Rollwinkeltrajektorien. Die Information der Kopfdrehung kann die Prädiktionsgüte sogar bis zur Prädiktionszeit von 3 s steigern und stellt damit nicht nur die Eingangsgröße mit der weitesten Vorausschau, sondern auch mit dem größten Einzeleffekt aller neuen Messgrößen dar.

Fahrer- und fahrtspezifische Auswertungen der lateralen Trajektorienprädiktion mithilfe von Kreuzvalidierungen zeigen eine um 3 % verschlechterte Rollwinkelprädiktion, wenn die Trajektorien eines unbekanntes, d.h. im Modelltraining nicht vertretenen, Fahrers vorhergesagt

werden. Eine weitere Steigerung der Generalisierbarkeit wird erwartet, wenn die Anzahl an Testfahrern im Training weiter erhöht wird. Die Diversität der Routen während der Datenerhebung schränkt den Vergleich von Fahrern stark ein, erzeugt jedoch eine sehr gute Generalisierung auf unbekannte Strecken.

In Pilotexperimenten wurde der Einsatz des entwickelten motorradspezifischen Modells zur lateralen Trajektorienprädiktion für die Prädiktion der Längsdynamik getestet. Eine Geschwindigkeitsprädiktion in Ergänzung zur Rollwinkelprädiktion bewirkt auch in den lateralen Metriken der Prädiktion deutliche Verbesserungen und eröffnet damit den Ausblick auf weitere Untersuchungen zur motorradspezifischen Trajektorienprädiktion.

Im Sinne der neuen Messgrößen querdynamisch wirksamer Fahrereingaben in der Lenkung und Fahrerbewegung lag der Fokus dieser Arbeit auf der lateralen Trajektorienprädiktion. In fortgehenden Untersuchungen zur Trajektorienprädiktion von Motorrädern sollte die manöverbasierte Prädiktion der Längsdynamik betrachtet werden. Bei Übernahme des RNN-basierten Prädiktionsansatzes für eine Geschwindigkeitsprädiktion können z.B. eine zielgerichtete Neuauswahl der Eingangsgrößen und eine erneute Modelloptimierung vorgenommen werden. Nachdem die motorradspezifische laterale Trajektorienprädiktion über den gesamten untersuchten Geschwindigkeitsbereich (> 30 km/h) konstant hohe Prädiktionsgüte erreicht hat, stellt sich für weitere Untersuchungen die Frage, inwiefern ein einziges Prädiktionsmodell auch im instabilen Bereich der Kippdynamik unterhalb von 30 km/h verwendet werden kann.

Obwohl das entwickelte Prädiktionsmodell mit 17396 trainierbaren Gewichten im Forschungsumfeld des maschinellen Lernens ein kleines RNN-Modell darstellt, bestehen diverse Methoden und das Potential, seine Größe und besonders auch den Rechenaufwand in der Inferenz zu miniaturisieren. Dies ist z.B. für eine echtzeitfähige Anwendung der Trajektorienprädiktion auf einem Endgerät mit limitierter Speicherkapazität und Rechenleistung sinnvoll. Zuerst könnte das bestehende Prädiktionsmodell mit „stateful“ LSTM-Schichten, die eine signifikante Reduktion des Rechenaufwands während der Inferenz ermöglichen, optimiert, trainiert und getestet werden.

Aus der Forschung zum automatisierten Fahren ist der erfolgreiche Einsatz multimodaler NN-Modelle für die Trajektorienprädiktion anderer Verkehrsteilnehmer (meist PKW) bekannt. Die Erweiterung der in dieser Arbeit verwendeten unimodalen Rollwinkelprädiktion in eine multimodale ist denkbar, wenn zusätzliche Information zur Auswahl der Mode – z.B. in Form des vorausliegenden Streckenverlaufs zur Verfügung steht.

Anstelle der Prädiktion einer vorausliegenden Trajektorie sollte auch die Option der probabilistischen Regression für die zukünftige Arbeit an der Trajektorienprädiktion in

Betracht gezogen werden. Diese bietet mit der Ausgabe einer Varianz die Möglichkeit, die Prädiktionsgüte zur Laufzeit einzuschätzen, was für die Verwendung der Trajektorienprädiktion in Assistenzfunktionen von Bedeutung sein kann.

Zuletzt ist die Fragestellung nach der Übertragbarkeit des Prädiktionsmodells, welches auf Fahrdaten eines einzigen Versuchsmotorrads trainiert wurde, auf andere Motorräder von Interesse. Dazu kann die kamerabasierte Messung von Fahreroberkörperposition und Kopfdrehung einfach übernommen werden. Die Ausrüstung der Lenkmoment-Sensorik verursacht hingegen den größten Aufwand. In einem ersten Schritt könnte daher das Standardmodell ohne neue Messgrößen auf Fahrdaten anderer Motorräder getestet werden.



Literaturverzeichnis

- [1] *Consolidated Resolution on the Construction of Vehicles (R.E.3): ECE/TRANS/WP.29/78/Rev.6*, Economic Commission for Europe, Jul. 2017.
- [2] World Health Organization, *Global status report on road safety 2023*. Genf, 2023. [Online]. Available: <https://www.who.int/teams/social-determinants-of-health/safety-and-mobility/global-status-report-on-road-safety-2023>
- [3] L. Cadavid and K. Salazar-Serna, "Mapping the Research Landscape for the Motorcycle Market Policies: Sustainability as a Trend—A Systematic Literature Review," *Sustainability*, vol. 13, no. 19, p. 10813, 2021, doi: 10.3390/su131910813.
- [4] Statista Inc., *Market Insights, Mobility, Motorcycles*. [Online]. Available: <https://www.statista.com/outlook/mmo/motorcycles/worldwide> (accessed: Nov. 15 2023).
- [5] N. Haworth, "Powered two wheelers in a changing world-challenges and opportunities," *Accident; analysis and prevention*, vol. 44, no. 1, pp. 12–18, 2012, doi: 10.1016/j.aap.2010.10.031.
- [6] L. Brown *et al.*, "Investigation of accidents involving powered two wheelers and bicycles - A European in-depth study," *Journal of safety research*, vol. 76, pp. 135–145, 2021, doi: 10.1016/j.jsr.2020.12.015.
- [7] European Commission, "Annual statistical report on road safety in the EU, 2021," European Commission, Directorate General for Transport, Brussels, 2022.
- [8] Europäische Kommission, Generaldirektion Mobilität und Verkehr, "EU Transport in Figures: Statistical Pocketbook 2020," doi:10.2832/919583, 2020.
- [9] T. Lich, W. G. Block, S. N. Prashanth, and B. Heiler, "Motorcycle Stability Control - The Next Generation of Motorcycle Safety and Riding Dynamics," *SAE Int. J. Engines*, vol. 9, no. 1, pp. 491–498, 2016, doi: 10.4271/2015-32-0834.
- [10] ACEM, "MAIDS In-depth investigation of accidents involving powered two wheelers: Final Report 2.0," Brussels, Belgium.
- [11] M. Köbe, "Entwicklung fahrdynamisch-eingreifender Fahrerassistenzsysteme für motorisierte Zweiräder," Dissertation, Eric Cuvillier; Technische Universität Dresden, 2023.
- [12] Honda Motor Co., Ltd., *Motorcycle Airbag System*. [Online]. Available: https://global.honda/en/tech/Motorcycle_Airbag_System/ (accessed: Jan. 9 2024).
- [13] P.-F. Tissot, O. Cherta Ballester, and V. Honoré, "Smart wearable airbads: Benefits for users and remaining challenges after 60 million kilometres and 3000 accidents," in *Sicherheit - Umwelt - Zukunft XIV: Tagungsband der 14. Internationalen Motorradkonferenz 2022*, 2022.
- [14] H. Winner, S. Hakuli, F. Lotz, and C. Singer, *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien Wiesbaden, 2015.
- [15] F. Passigato, A. Wischnewski, A. Gordner, and F. Diermeyer, "Two Approaches for the Synthesis of a Weave-Wobble-stabilizing Controller in Motorcycles," in *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, Indianapolis, IN, USA, 2021, pp. 3496–3501.
- [16] A. Wahl, M. Klews, and A. Georgi, "Safety System for Preventing Lateral Sliding in Curves," *ATZ Worldw*, vol. 120, no. 9, pp. 58–61, 2018, doi: 10.1007/s38311-018-0110-z.

-
- [17] C. Lucci, P. Huertas-Leyva, M. Marra, M. Pierini, G. Savino, and N. Baldanzini, "Autonomous Emergency Braking system for Powered-Two-Wheelers: testing end-user acceptability of unexpected automated braking events deployed in typical pre-crash trajectories," in *Sicherheit - Umwelt - Zukunft XIII: Tagungsband der 13. Internationalen Motorradkonferenz*, 2020. [Online]. Available: https://www.ifz.de/imc/session3/imc2020-session3-lucci_paperifz_final.pdf
- [18] M. Bartolozzi, A. Niccolai, C. Lucci, and G. Savino, "Motorcycle emergency steering assistance: A systematic approach from system definition to benefit estimation and exploratory field testing," *Accident; analysis and prevention*, vol. 188, p. 107116, 2023, doi: 10.1016/j.aap.2023.107116.
- [19] F. Biral, P. Bosetti, and R. Lot, "Experimental evaluation of a system for assisting motorcyclists to safely ride road bends," *Eur. Transp. Res. Rev.*, vol.6, no.4, pp. 411–423, 2014, doi: 10.1007/s12544-014-0140-6.
- [20] S. Hecker, A. Liniger, H. Maurenbrecher, D. Dai, and L. van Gool, "Learning a Curve Guardian for Motorcycles," in *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, Auckland, New Zealand, 2019, pp. 2984–2991.
- [21] CMC (Connected Motorcycle Consortium) GbR, *Applications to improve rider safety*. [Online]. Available: <https://www.cmc-info.net/applications.html> (accessed: Feb. 3 2023).
- [22] Connected Motorcycle Consortium, "Path Prediction for PTWs: CMC Whitepaper," Apr. 2023. [Online]. Available: https://www.cmc-info.net/uploads/1/2/1/4/121453783/whitepaper_path_prediction.pdf
- [23] L. Sulzberger, D. Schmidt, G.-L. Mantovani, M. Pfäffli, and T. Lich, "Retrospective benefit estimation of motorcycle ABSs based on Swiss insurance data," *Traffic injury prevention*, vol. 24, no. 5, pp. 423–427, 2023, doi: 10.1080/15389588.2023.2199111.
- [24] J. Kooijman and A. L. Schwab, "A review on bicycle and motorcycle rider control with a perspective on handling qualities," *Vehicle System Dynamics*, vol. 51, no. 11, pp. 1722–1764, 2013, doi: 10.1080/00423114.2013.824990.
- [25] A. Aoki, "Experimental Study on Motorcycle Steering Performance," in *SAE Technical Paper Series*, 1979.
- [26] T. Katayama, A. Aoki, and T. Nishimi, "Control Behaviour of Motorcycle Riders," *Vehicle System Dynamics*, vol. 17, no. 4, pp. 211–229, 1988, doi: 10.1080/00423118808968903.
- [27] R. S. Sharp, "Optimal linear time-invariant preview steering control for motorcycles," *Vehicle System Dynamics*, vol. 44, sup1, pp. 329–340, 2006, doi: 10.1080/00423110600871509.
- [28] R. S. Sharp, "Motorcycle Steering Control by Road Preview," *Journal of Dynamic Systems, Measurement, and Control*, vol. 129, no. 4, pp. 373–381, 2007, doi: 10.1115/1.2745842.
- [29] A. A. Popov, S. Rowell, and J. P. Meijaard, "A review on motorcycle and rider modelling for steering control," *Vehicle System Dynamics*, vol. 48, no. 6, pp. 775–792, 2010, doi: 10.1080/00423110903033393.
- [30] M. Evertse, "Rider Analysis using a fully instrumented motorcycle," Master of Science Thesis, Faculty of Aerospace Engineering, Delft University of Technology, 2010.
- [31] M. Bartolozzi, G. Savino, and M. Pierini, "Motorcycle steering torque estimation using a simplified front assembly model: experimental validation and manoeuvrability implications," *Vehicle System Dynamics*, pp. 1–26, 2023, doi: 10.1080/00423114.2023.2194542.
- [32] M. Bruschetta *et al.*, "Real-Time Nonlinear Model Predictive Control of a Virtual Motorcycle," *IEEE Transactions on Control Systems Technology*, pp. 1–9, 2020, doi: 10.1109/TCST.2020.3022462.
- [33] F. Scherer, R. Pleß, and H. Winner, "Identification of Rider-Vehicle Coupling on Motorcycles and Riding Simulators," in *Proceedings, Bicycle and Motorcycle Dynamics 2019: Symposium on the Dynamics and*

- Control of Single Track Vehicles*, University of Padova, Italy, 2019. [Online]. Available: <https://doi.org/10.6084/m9.figshare.12363713.v1>
- [34] S. Zhu, S. Murakami, and H. Nishimura, "Motion analysis of a motorcycle taking into account the rider's effects," *Vehicle System Dynamics*, vol. 50, no. 8, pp. 1225–1245, 2012, doi: 10.1080/00423114.2012.660166.
- [35] V. Cossalter, A. Doria, R. Lot, and M. Massaro, "The effect of rider's passive steering impedance on motorcycle stability: identification and analysis," *Meccanica*, vol. 46, no. 2, pp. 279–292, 2011, doi: 10.1007/s11012-010-9304-1.
- [36] T. Lane and R. Lot, "The link between roll and steering torque in motorcycles," in *World Congress on Engineering: WCE 2018*, Imperial College London, London U.K, 2018, pp. 727–731.
- [37] M. Winkelbauer, P. Krack, and D. Lamp, "Lean Angles and Lane Positions of Motorcyclists," in *Sicherheit - Umwelt - Zukunft XII: Tagungsband der 12. Internationalen Motorradkonferenz*, 2018.
- [38] N. Magiera, "Identifikation des Fahrfertigkeitsniveaus von Motorradfahrern in Kurvenfahrt im Realverkehr," Technische Universität Darmstadt, 2020.
- [39] M. Bartolozzi, A. Boubezoul, S. Bouaziz, G. Savino, and S. Espié, "Understanding the behaviour of motorcycle riders: An objective investigation of riding style and capability," *Transportation Research Interdisciplinary Perspectives*, vol. 22, p. 100971, 2023, doi: 10.1016/j.trip.2023.100971.
- [40] S. Will *et al.*, "Methodological considerations regarding motorcycle naturalistic riding investigations based on the use of g-g diagrams for rider profile detection," *Safety Science*, vol. 129, p. 104840, 2020, doi: 10.1016/j.ssci.2020.104840.
- [41] F. Scherer and T. Basten, "Entwicklung eines Motorradfahrendenmodells zur Trajektorienprädiktion," in *Sicherheit - Umwelt - Zukunft XIV: Tagungsband der 14. Internationalen Motorradkonferenz 2022*, 2022, pp. 265–299.
- [42] F. Cheli, P. Mazzoleni, M. Pezzola, E. Ruspini, and E. Zappa, "Vision-based measuring system for rider's pose estimation during motorcycle riding," *Mechanical Systems and Signal Processing*, vol. 38, no. 2, pp. 399–410, 2013, doi: 10.1016/j.ymsp.2013.01.009.
- [43] M. Boccione, F. Cheli, E. Leo, and M. Pezzola, "Experimental Identification of Kinematic Coupled Effects between Driver - Motorcycle," in *Modal Analysis Conference 2007*, 2007, pp. 2688–2697.
- [44] H. Prem and M. Good, "A Rider-Lean Steering Mechanism for Motorcycle Control," *Vehicle System Dynamics*, vol. 12, 1-3, pp. 29–32, 1983, doi: 10.1080/00423118308968712.
- [45] R. Lot and V. Cossalter, "A non-linear rider model for motorcycles," in *FISITA 2006, World Automotive Congress*, Yokohama, Japan, 2006, F2006V075.
- [46] M. Massaro, R. Lot, and V. Cossalter, "A virtual motorcycle driver to simulate real manoeuvres from experimental data," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 226, no. 9, pp. 1211–1219, 2012, doi: 10.1177/0954407012440217.
- [47] S. Lefèvre, D. Vasquez, and C. Laugier, "A survey on motion prediction and risk assessment for intelligent vehicles," *Robomech J*, vol. 1, no. 1, 2014, doi: 10.1186/s40648-014-0001-z.
- [48] A. Houenou, P. Bonnifait, V. Cherfaoui, and W. Yao, "Vehicle trajectory prediction based on motion model and maneuver recognition," in *2013 IEEE/RSJ International Conference 2013*, 2013, pp. 4363–4369.
- [49] S. Casas, W. Luo, and R. Urtasun, "IntentNet: Learning to Predict Intention from Raw Sensor Data," Jan. 2021. [Online]. Available: <http://arxiv.org/pdf/2101.07907v1>

-
- [50] H. Berkemeyer, R. Franceschini, T. Tran, L. Che, and G. Pipa, "Feasible and Adaptive Multimodal Trajectory Prediction with Semantic Maneuver Fusion," in *2021 IEEE International Conference on Robotics and Automation (ICRA)*, Xi'an, China, 2021, pp. 8530–8536.
- [51] A. Benterki, M. Boukhniher, V. Judalet, and C. Maaoui, "Artificial Intelligence for Vehicle Behavior Anticipation: Hybrid Approach Based on Maneuver Classification and Trajectory Prediction," *IEEE Access*, vol. 8, pp. 56992–57002, 2020, doi: 10.1109/ACCESS.2020.2982170.
- [52] H. Cui *et al.*, "Multimodal Trajectory Predictions for Autonomous Driving using Deep Convolutional Networks," in *2019 International Conference on Robotics and Automation (ICRA)*, Montreal, QC, Canada, 2019, pp. 2090–2096.
- [53] F. Altche and A. de La Fortelle, "An LSTM network for highway trajectory prediction," in *IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, Yokohama, 2017, pp. 353–359.
- [54] S. Mozaffari, O. Y. Al-Jarrah, M. Dianati, P. Jennings, and A. Mouzakitis, "Deep Learning-Based Vehicle Behavior Prediction for Autonomous Driving Applications: A Review," *IEEE Trans. Intell. Transport. Syst.*, vol. 23, no. 1, pp. 33–47, 2022, doi: 10.1109/TITS.2020.3012034.
- [55] S. Dai, L. Li, and Z. Li, "Modeling Vehicle Interactions via Modified LSTM Models for Trajectory Prediction," *IEEE Access*, vol. 7, pp. 38287–38296, 2019, doi: 10.1109/ACCESS.2019.2907000.
- [56] X. Li, X. Ying, and M. C. Chuah, "GRIP: Graph-based Interaction-aware Trajectory Prediction," in *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, Auckland, NZ, 2019, pp. 3960–3966.
- [57] N. Deo and M. M. Trivedi, "Multi-Modal Trajectory Prediction of Surrounding Vehicles with Maneuver based LSTMs," in *2018 IEEE Intelligent Vehicles Symposium (IV)*, Changshu, 2018, pp. 1179–1184.
- [58] F. Wirth, T. Wen, C. Fernandez-Lopez, and C. Stiller, "Model-Based Prediction of Two-Wheelers," in *2020 IEEE Intelligent Vehicles Symposium (IV)*, Las Vegas, NV, USA, 2020, pp. 1669–1674.
- [59] F. Scherer and M. Eschinger, "Investigation of the Applicability of a Motorcyclist Model for Trajectory Prediction in Real Traffic," in *The Evolving Scholar - BMD 2023, 5th Edition*, 2023.
- [60] F. Immel, "Development of a Trajectory Prediction for Bicycles for Driver Assistance Functions Based on Vehicle2Vehicle Communication," Master Thesis, Institute of Measurement and Control Systems, Karlsruhe Institute of Technology, Karlsruhe, 2022.
- [61] *Straßenfahrzeuge - Fahrzeugdynamik und Fahrverhalten - Begriffe*, DIN ISO 8855:2013-11, DIN Deutsches Institut für Normung e.V. [Online]. Available: Berlin
- [62] V. Cossalter, R. Lot, and M. Peretto, "Steady turning of motorcycles," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 221, no. 11, pp. 1343–1356, 2007, doi: 10.1243/09544070JAUTO322.
- [63] J. K. Moore, "Human Control of a Bicycle," Dissertation, University of California, Davis, 2012.
- [64] S. M. Cain, "An Experimental Investigation of Human/Bicycle Dynamics and Rider Skill in Children and Adults," Dissertation, University of Michigan, 2013.
- [65] S. M. Cain, J. A. Ashton-Miller, and N. C. Perkins, "On the Skill of Balancing While Riding a Bicycle," *PloS one*, vol. 11, no. 2, 2016, doi: 10.1371/journal.pone.0149340.
- [66] J. Meijaard, J. M. Papadopoulos, A. Ruina, and A. Schwab, "Linearized dynamics equations for the balance and steer of a bicycle: a benchmark and review," *Proc. R. Soc. A.*, vol. 463, no. 2084, pp. 1955–1982, 2007, doi: 10.1098/rspa.2007.1857.
- [67] R. S. Sharp, "Stability, Control and Steering Responses of Motorcycles," *Vehicle System Dynamics*, vol. 35, 4-5, pp. 291–318, 2001, doi: 10.1076/vesd.35.4.291.2042.

- [68] V. Cossalter, *Motorcycle dynamics*, 2nd ed.: Lulu, 2006.
- [69] S. Bruni, J. P. Meijaard, G. Rill, and A. L. Schwab, "State-of-the-art and challenges of railway and road vehicle dynamics with multibody dynamics approaches," *Multibody System Dynamics*, vol. 49, no. 1, pp. 1–32, 2020, doi: 10.1007/s11044-020-09735-z.
- [70] B. Spiegel, *Die obere Hälfte des Motorrads*, 7th ed. Stuttgart: Motorbuch-Verl., 2012.
- [71] V. Cossalter, R. Lot, M. Massaro, M. Peretto, and A. M. Korsunsky, "Investigation of Motorcycle Steering Torque Components," in *CURRENT THEMES IN ENGINEERING SCIENCE 2010: World Congress on Engineering—2010*, London, (United Kingdom), 2011, pp. 35–46.
- [72] V. Cossalter and J. Sadauckas, "Elaboration and quantitative assessment of manoeuvrability for motorcycle lane change," *Vehicle System Dynamics*, vol. 44, no. 12, pp. 903–920, 2006, doi: 10.1080/00423110600742072.
- [73] R. Pleß, "Dual Loop Rider Control of a Dynamic Motorcycle Riding Simulator," Dissertation, Technische Universität Darmstadt, 2023.
- [74] E. Leo, M. E. Pezzola, C. Pagliara, and G. Morandin, "Effects of tire wear on motorcycle dynamic," in *Proceedings, Bicycle and Motorcycle Dynamics 2019: Symposium on the Dynamics and Control of Single Track Vehicles*, University of Padova, Italy, 2019.
- [75] T. Müller, *Spielarten der Künstlichen Intelligenz: Maschinelles Lernen und Künstliche Neuronale Netze*. [Online]. Available: <https://blog.iao.fraunhofer.de/spielarten-der-kuenstlichen-intelligenz-maschinelles-lernen-und-kuenstliche-neuronale-netze/> (accessed: Jan. 23 2024).
- [76] F. M. Bianchi, E. Maiorino, M. C. Kampffmeyer, A. Rizzi, and R. Jenssen, *Recurrent neural networks for short-term load forecasting: An overview and comparative analysis*. Cham: Springer, 2017.
- [77] PyTorch Contributors, *PyTorch Docs, torch.nn, LSTM*. [Online]. Available: <https://pytorch.org/docs/stable/generated/torch.nn.LSTM.html> (accessed: Jan. 23 2024).
- [78] N. S. Keskar, D. Mudigere, J. Nocedal, M. Smelyanskiy, and P. T. P. Tang, "On Large-Batch Training for Deep Learning: Generalization Gap and Sharp Minima," in *5th International Conference on Learning Representations, ICLR*, Toulon, France, 2017.
- [79] G. Matschl, M. Moerbe, and C. Groeger, "Motorcycle Stability Control - MSC. The next step into safety solutions for motorcycles," in *Tagungsband der 10. Internationalen Motorradkonferenz2014*, pp. 128–154.
- [80] P. Loiseau, C. N. E. Boultifat, P. Chevrel, F. Claveau, S. Espié, and F. Mars, "Rider model identification: neural networks and quasi-LPV models," *IET intell. transp. syst.*, vol. 14, no. 10, pp. 1259–1264, 2020, doi: 10.1049/iet-its.2020.0088.
- [81] A. Wahl, F. Kaut, E. Dikmenli, and M. Klews, "Steering Torque Measurement on Motorcycles," in *Sicherheit - Umwelt - Zukunft XIII: Tagungsband der 13. Internationalen Motorradkonferenz*, 2020. [Online]. Available: https://www.ifz.de/imc/session5/imc2020-session5-steertorque_final.pdf
- [82] T. Toyota, N. Hara, Y. Fukuhara, and T. Nagata, "Leaning Vehicle," EP 3290318 B1.
- [83] M. Nugent, S. Espié, F. Delgehier, and S. Bouaziz, "Coordination patterns in arm versus body steering strategies in free slalom on a motorcycle: A single case pilot study," in *Sicherheit - Umwelt - Zukunft XIII: Tagungsband der 13. Internationalen Motorradkonferenz*, 2020, pp. 308–317.
- [84] S. Keil, *Dehnungsmessstreifen*, 2nd ed. Wiesbaden, Heidelberg: Springer Vieweg, 2017.
- [85] Y. Zhang, "Modeling and Control of Single-Track Vehicles: a Human-Machine-Environment Interactions Perspective," Dissertation, The State University of New Jersey, New Brunswick, New Jersey, USA, 2014.

-
- [86] F. Carputo, D. D'Andrea, G. Risitano, A. Sakhnevych, D. Santonocito, and F. Farroni, "A Neural-Network-Based Methodology for the Evaluation of the Center of Gravity of a Motorcycle Rider," *Vehicles*, vol. 3, no. 3, pp. 377–389, 2021, doi: 10.3390/vehicles3030023.
- [87] A. Tözeren, *Human Body Dynamics: Classical Mechanics and Human Movement*. New York: Springer-Verlag, 2000.
- [88] K. L. Stolle, A. Wahl, and S. Schmidt, "Motorcycle rider posture measurement for on-road experiments on rider intention detection," in *2022 IEEE 1st International Conference on Cognitive Mobility (CogMob)*, Budapest, Hungary, 2022, pp. 51–56.
- [89] E. Olson, "AprilTag: A robust and flexible visual fiducial system," in *2011 IEEE International Conference on Robotics and Automation*, Shanghai, China, 2011, pp. 3400–3407.
- [90] J. Wang and E. Olson, "AprilTag 2: Efficient and robust fiducial detection," in *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Daejeon, South Korea, 2016, pp. 4193–4198.
- [91] Kraftfahrt-Bundesamt, *Durchschnittliche Jahresfahrleistung in km nach Fahrzeugarten seit 2018*. [Online]. Available: https://www.kba.de/DE/Statistik/Kraftverkehr/VerkehrKilometer/vk_inlaenderfahrleistung/2022/2022_vk_tabellen.html?nn=3517388&fromStatistic=3517388&yearFilter=2022&fromStatistic=3517388&yearFilter=2022 (accessed: Feb. 3 2024).
- [92] M. Bartolozzi, A. Boubezoul, S. Bouaziz, G. Savino, and S. Espié, "Data-Driven Methodology for the Investigation of Riding Dynamics: A Motorcycle Case Study," *IEEE Trans. Intell. Transport. Syst.*, vol. 24, no. 9, pp. 10224–10237, 2023, doi: 10.1109/TITS.2023.3271790.
- [93] T. Smith, S. Garets, J. Cicchino, and T. Tucker, "Visual Scanning of Motorcycle Riders a Preliminary Look," in *IMSC International Motorcycle Safety Conference: „the human element: the way forward“*, Orlando, Florida, USA, 2013.
- [94] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, "Optuna," in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Anchorage AK USA, 2019, pp. 2623–2631.
- [95] *On-Board System Requirements for V2V Safety Communications*, SAE J2945/1, SAE International, Apr. 2020.
- [96] V. Noroozi, S. Majumdar, A. Kumar, J. Balam, and B. Ginsburg, "Stateful Conformer with Cache-based Inference for Streaming Automatic Speech Recognition," Dec. 2023. [Online]. Available: <http://arxiv.org/pdf/2312.17279v2>
- [97] M. Pschenitzka, "Auswertung von Motorradunfällen: Konstellationen, Besonderheiten, Abhilfemaßnahmen," *Berichte der ADAC Unfallforschung*, ADAC Unfallforschung, Apr. 2015, aktualisiert Feb. 2019. Accessed: Nov. 27 2023. [Online]. Available: https://www.adac.de/-/media/pdf/rund-ums-fahrzeug/auswertung_motorradunfalle_1005kb.pdf
- [98] F. Scherer *et al.*, Eds., *Schräglagenangst*. Bremen: Fachverlag NW in Carl Ed. Schünemann KG, 2021. [Online]. Available: <https://bast.opus.hbz-nrw.de/>

Publikationsliste

Teile der Dissertation wurden in den folgenden Publikationen veröffentlicht:

K. L. Stolle, A. Wahl, and S. Schmidt, "Importance of motorcycle rider upper body movement for rider intention detection and motorcycle state prediction," in *Sicherheit - Umwelt - Zukunft XIV: Tagungsband der 14. Internationalen Motorradkonferenz 2022*, 2022, pp. 32–41.

https://www.ifz.de/wordpress/wp-content/uploads/2022/10/ifz_Forschungsheft_20.pdf

K. L. Stolle, A. Wahl, and S. Schmidt, "Motorcycle rider posture measurement for on-road experiments on rider intention detection," in *2022 IEEE 1st International Conference on Cognitive Mobility (CogMob)*, Budapest, Hungary, 2022, pp. 51–56.

<https://doi.org/10.1109/CogMob55547.2022.10118004>

K. L. Stolle, A. Wahl, and S. Schmidt, "Trajectory Forecasting for Powered Two Wheelers by Roll Angle Prediction with an LSTM Network," in *The Evolving Scholar - BMD 2023, 5th Edition*, 2023.

<https://doi.org/10.59490/64e61a33563addeb42473c8f>



Anhang

A.1 Unfallgeschehen des Motorrads in Europa

In den folgenden Absätzen wird ein kurzer Einblick in das Unfallgeschehen im Zusammenhang mit dem Motorrad in Europa gegeben. Dies soll die Motivation für die Entwicklung aktiver Motorradsicherheitssysteme bestärken und motorradspezifische Herausforderungen hervorheben.

Drei Viertel der schwer verletzten oder getöteten Motorradfahrer in Europa sind auf Kollisionen mit anderen Verkehrsteilnehmern – hauptsächlich PKW – zurückzuführen, wobei die folgend aufgezählten Ursachen mit absteigender Häufigkeit vorliegen [6]:

- verpasste oder zu späte Wahrnehmung (hauptsächlich auf Seiten des Unfallgegners),
- nicht angepasste Geschwindigkeit,
- Sichtverdeckung und
- mangelnde Fahrerfahrung.

Zu einem hohen Anteil ist dabei der Unfallgegner schuld an der Kollision [5]. Dafür prädestinierte Unfallszenarien sind kreuzender Verkehr, Spurwechsel, Linksabbiege- und Wendemanöver [22]. Zudem identifiziert die motorradspezifische Unfallforschung Risikofaktoren, welche eine schwere Verletzung bei Kollisionen begünstigen. Ein wesentlicher Risikofaktor ist der Sturz des Fahrers vor der Kollision, der meist durch eine falsche Fahrerreaktion verursacht wird. So führt z.B. das schreckhafte Überbremsen des Vorderrads auf einem Motorrad ohne ABS zu einem blockierenden Rad und damit zu einem sicheren Sturz. Mittels der retrospektiven Unfallanalyse wurde abgeschätzt, dass die Einführung einer ABS-Pflicht – je nach Region in der Welt – ein Unfallreduktionspotential zwischen 20 und 34 % birgt [23].

Das verbleibende Viertel der schwer verletzten oder getöteten Motorradfahrer in Europa ist auf Alleinunfälle zurückzuführen, von denen 64 % in Kurvenfahrt passieren [6]. Als Hauptursache für diesen Unfalltyp werden Fahrfehler festgestellt, die sich zumeist in einem Sturz aufgrund unangepasster Kurvengeschwindigkeit oder dem Abkommen von der Fahrbahn äußern [20, 97]. Nur in seltenen Fällen ist ein Alleinunfall unvermeidbar, weil die physikalische Haftungsgrenze der Reifen überschritten wird (z.B. Sturz auf einem Ölfleck). Stattdessen treten Alleinunfälle

häufig diesseits des physikalischen Grenzbereichs auf, indem Stürze oder das Abkommen von der Fahrbahn durch falsche Fahrerhandlungen verursacht werden. Ein bekanntes Phänomen mangelnder Fahrfertigkeit in Kurvenfahrt ist die Schräglagenangst: der Motorradfahrer verlässt hierbei die Fahrspur nach kurvenaußen, weil er die Schräglage nicht mehr erhöht, obwohl dies physikalisch noch möglich gewesen wäre [98].

A.2 Analytische Berechnungen zur DMS-Auslegung

Folgend sind die Rechenschritte erläutert, die zur Auswahl der Empfindlichkeit der Messverstärker bei der Auslegung des DMS-Messsystems notwendig sind. Zu den parametrischen Gleichungen werden die Ergebnisse einzelner Rechenschritte für das realisierte Messsystem zur Lenk- und Abstützmoment-Messung am Versuchsmotorrad angegeben (siehe Abschnitt 4.2). Sie basieren auf den in Tabelle A.1 gesammelten Parameterwerten. Trotzdem in den Gleichungen nur das Lenkmoment M_z genannt wird, gelten diese ebenso für das Abstützmoment M_x .

Parameter	Wert
d_a	28,5 mm
d_i	21,1 mm
E	70000 N/mm ²
l_{DMS}	282,5 mm
l_H	347,5 mm
$M_{z,\text{max}}$	120 Nm
k	2 (metallische DMS)
B	4 (Vollbrücke)
U_E	4,096 V (gegeben durch Messverstärker)
G	1,5 mV/V
$U_{A,\text{range}}$	5 V (0...5 V)

Tabelle A.1: Parameter und Werte des DMS-Messsystems am Lenker des Versuchsmotorrads.

Im ersten Schritt wird die Dehnung der Komponente an der Stelle der DMS als Reaktion auf den Lastfall von Interesse errechnet. Für die Lenkmomentmessung an der runden Lenkstange ist dies der in Formel (A.1) gegebene Quotient aus Dehnung ϵ und Biegemoment M_b . Die Formel ergibt sich aus dem Widerstandsmoment gegen Biegung eines Rohrs mit Außen- und

Innendurchmesser d_a und d_i sowie unter Annahme von Spannungen im elastischen Bereich des Werkstoffs mit dem Elastizitätsmodul E .

$$\frac{\epsilon}{M_b} = \frac{32}{\pi} \cdot \frac{d_a}{E(d_a^4 - d_i^4)} = 8,99 \frac{\mu\text{m/m}}{\text{Nm}} \quad (\text{A.1})$$

Aus dem maximal zu messenden Lenkmoment je Lenkerhälfte $M_{z,\text{max}}/2$ werden das maximale Biegemoment $M_{b,\text{max}}$ und die maximale Dehnung ϵ_{max} aus den Formeln (A.2) bestimmt. Hierin sind l_{DMS} und l_{H} die Hebellängen an der Lenkstange entsprechend Abbildung 4.1.

$$M_{b,\text{max}} = \frac{M_{z,\text{max}}}{2} \cdot \frac{l_{\text{DMS}}}{l_{\text{H}}} = 48,78 \text{ Nm} \quad (\text{A.2})$$

$$\epsilon_{\text{max}} = M_{b,\text{max}} \frac{\epsilon}{M_b} = 438,28 \mu\text{m/m}$$

Für die Differenzspannung U_{D} einer DMS-Brückenschaltung unter Dehnung ϵ gilt Gleichung (A.3). Hierin ist k ein DMS spezifischer Verstärkungsfaktor, B der Brückenfaktor in Abhängigkeit von Art und Anzahl verschalteter DMS in der Messbrücke und U_{E} die Versorgungsspannung der Messbrücke.

$$U_{\text{D}} = \frac{1}{4} k B \epsilon U_{\text{E}} \quad (\text{A.3})$$

$$U_{\text{D,max}} = 3,59 \text{ mV}$$

Entsprechend Formel (A.4) wird die Differenzspannung U_{D} mit der Empfindlichkeit G des Messverstärkers in die Ausgangsspannung U_{A} überführt. G ist in Schritten am Messverstärker einstellbar und sollte möglichst niedrig gewählt werden, damit eine hohe Sensitivität und damit Messgenauigkeit erreicht wird. Durch die Anforderung des Messbereichs und die Limitierung des verfügbaren Bereichs der Ausgangsspannung $U_{\text{A,range}}$ des Messverstärkers hat die Wahl von G aber auch eine untere Grenze. Weil das maximale Lenkmoment $M_{z,\text{max}}$ auf dem Versuchsmotorrad in beide Vorzeichenrichtungen gemessen werden soll, muss die dabei maximal auftretende Ausgangsspannung $U_{\text{A,max}}$ auf die Hälfte des verfügbaren Bereichs ($U_{\text{A,range}}/2$) begrenzt werden. An den Messverstärkern der DMS an der Lenkstange wird eine Empfindlichkeit G von 1,5 mV/V ausgewählt, sodass der halbe Messbereich mit 2,394 V von maximal 2,5 V fast vollständig ausgenutzt wird.

$$U_{\text{A}} = \frac{U_{\text{D}}}{G} \quad (\text{A.4})$$

$$U_{\text{A,max}} = 2,394 \text{ V} < U_{\text{A,range}}/2$$

Basierend auf dem gewählten G und einem maximal zu erwartenden Fehler von 0,03 % in der Ausgangsspannung, angegeben in den Kalibrierscheinen der Messverstärker, kann mittels Formel (A.5) der zu erwartende Fehler im gemessenen Lenkmoment $M_{z,E}$ berechnet werden.

$$M_{z,E} = \frac{0,03 \% \cdot U_{A,\text{range}} \cdot G}{\frac{\epsilon}{M_b} \cdot \frac{1}{4} \cdot k \cdot B \cdot U_E} = 0,031 \text{ Nm} \quad (\text{A.5})$$

A.3 Algorithmus zur Bestimmung der Fahrerposition aus Markerpositionen

Aus einer Videoaufnahme zur Fahrerpositionserfassung werden in einem ersten Algorithmus die dreidimensionalen Positionen und Orientierungen der erkannten Marker in jedem Frame ermittelt. Das verwendete Kamera-KS hat dabei die X_C -Achse orthogonal aus der Bildebene herausstehen, die Y_C -Achse zeigt in Fahrrichtung gesehen nach links und ist damit parallel zur Y_V -Achse, und die Z_C -Achse zeigt nach oben und liegt in der X_V - Z_V -Ebene des Fahrzeug-KS. Anhand des folgend beschriebenen zweiten Algorithmus wird aus den Markerpositionen die Fahrerposition, angegeben in Neigungswinkel φ_F und lateralem Versatz $y_{F,M5}$ des Fahrer-oberkörpers relativ zum Motorrad, errechnet.

Einmalig je Videoaufnahme werden die folgenden Auswertungen durchgeführt:

- Die Detektionen der Referenzmarker auf dem Tank des Motorrads werden aus allen Frames gesammelt. Auf allen Y_C - und Z_C -Koordinaten wird eine zweidimensionale Regression durchgeführt, deren Ergebnis die Motorradmittellinie darstellt.

Für einzelne Frames werden die folgenden Auswertungen wiederholt durchgeführt, bis das gesamte Video verarbeitet ist:

- Aus den Y_C - und Z_C -Koordinaten der erkannten Marker entlang Mittellinie der Protektorweste wird per zweidimensionaler Regression die Rückenlinie errechnet. Ist die Mindestanzahl von zwei Markern nicht vorhanden, wird die letzte bekannte Rückenlinie für maximal 20 aufeinanderfolgende Frames (entspricht 200 ms) wiederholt, ansonsten kann keine Rückenlinie ausgegeben werden.
- Der Vergleich der Gradienten der Regressionsgerade der Rückenlinie mit dem der Motorradmittellinie ergibt den Neigungswinkel φ_F . Dazu wird die Differenz vom Arkustangens beider Gradienten gebildet.

- Zuletzt wird der laterale Versatz $y_{F,M5}$ von Marker 5 relativ zur Motorradmittellinie errechnet. Dies entspricht der Problemstellung vom kürzesten Abstand zwischen Punkt und Gerade. Es wird die Differenz der Y_C -Koordinate von Marker 5 mit der Y_C -Position der Motorradmittellinie auf Z_C -Höhe von Marker 5 gebildet. Diese wird anschließend mit dem Kosinus des Winkels der Motorradmittellinie gegenüber der Z_C -Achse multipliziert. Liegt keine Detektion von Marker 5 vor, wird vom nächstgelegenen erkannten Marker entlang der Rückenlinie auf die erwartete Position von Marker 5 heruntergerechnet. Hierfür sind Referenzwerte der vertikalen Abstände der Marker hinterlegt.
- Extraschritt: zur Bestimmung des Kopfdrehwinkels ψ_H werden die Y_C - und Z_C -Koordinaten von mindestens einem der drei Marker am Helm des Motorradfahrers benötigt. Es wird der Abstand der Marker orthogonal zur Rückenlinie berechnet. Dies geschieht analog zum Vorgehen zur Berechnung des lateralen Versatzes $y_{F,M5}$. Für jeden Helmmarker ist eine Kennlinie aus einer Referenzmessung hinterlegt, welche den Abstand in einen Drehwinkel übersetzt. Bei mehreren erkannten Helmmarkern in einem Frame werden die Ergebnisse gemittelt.

A.4 Vorfragebogen der Datenerhebung zum Realfahrverhalten

Vorfragebogen

Wie alt sind Sie? _____ Jahre

Sie sind männlich weiblich

Wie groß sind Sie? _____ m

Was ist ihr aktuelles Körpergewicht inkl. Motorradschutzbekleidung (geschätzt)?
_____ kg

Wie lange haben Sie schon den Motorradführerschein? _____ Jahre

Wie viele Kilometer sind Sie schätzungsweise schon mit dem Motorrad gefahren

Vergangene Saison (2021) ca. _____ km

Insgesamt seit Führerscheinwerb ca. _____ km

Welches Motorrad fahren sie derzeit am häufigsten:

Motorrad 1: Hersteller: _____ Typ: _____

Motorrad 2: Hersteller: _____ Typ: _____

Das Motorrad nutzen Sie als...

Transportmittel (bspw. Arbeitsweg) 100% 80% 60% 40% 20% 0%

Sportgerät (bspw. Rennstrecke) 100% 80% 60% 40% 20% 0%

Ausflugsmittel (bspw. Touren in Alpen) 100% 80% 60% 40% 20% 0%

Wie oft fahren Sie mit Sozius/Sozia?

Anteil der Fahrten 100% 80% 60% 40% 20% 0%

Sind sie schon einmal auf der Rennstrecke Motorrad gefahren?

nein ja ca. _____mal

Wie häufig begeben Sie sich mit ihrem Motorrad auch in den fahrdynamischen Grenzbereich?

nie selten manchmal häufig immer

Wie sicher fühlen Sie sich in der Regel, wenn Sie das Motorrad im Grenzbereich bewegen?

Überhaupt nicht sicher völlig sicher

Ich betrachte meinen Fahrstil als

- Grundsätzlich komfortorientiert
- Überwiegend komfortorientiert
- Je nach Stimmungslage komfortorientiert bis sportlich
- Überwiegend sportlich
- Grundsätzlich sportlich

Ich schätze mich als Motorradfahrer ein als

sicherheitsorientiert risikofreudig

Wie häufig nutzen Sie ein Navigationssystem auf dem Motorrad?

nie selten manchmal häufig immer

Ich nutze die Routenvorausschau meines Navigationssystems während der Fahrt, um meine Geschwindigkeit an den vorausliegenden Streckenverlauf anzupassen?

nie selten manchmal häufig immer

Wie groß ist der Anteil der folgenden Streckentypen an der Gesamtfahrleistung im Jahr:

in Prozent, alles zusammen muss 100% ergeben

- **Gänzlich unbekannte Strecken:**
(Streckenverlauf ist unbekannt): _____

- **Selten befahrene Strecken (1-2mal im Jahr)**
(Streckenverlauf ist nicht mehr genau in Erinnerung): _____

- **Regelmäßig befahrene Strecken (bis 10mal im Jahr):**
(Streckenverlauf ist noch in Erinnerung): _____

- **Häufig befahrene Strecken (Hausstrecke, >10mal im Jahr, Strecke zur Arbeit)**
(Streckenverlauf kennt man im Schlaf): _____

Testprotokoll Fahrt

Datum: _____

Start, Uhrzeit: _____

Ende, Uhrzeit: _____

Wetter _____

Bemerkungen _____

Nachfragebogen

Gab es besondere Fahrsituationen? (Überholmanöver, Gefahrenbremsungen, Fahrfehler, etc.)

Sonstige Bemerkungen, Hinweise, Feedback?

A.5 Zustandsautomat zur Klassifikation querdynamischer Manöversegmente

Abbildung A.1 zeigt den Aufbau des geschichteten Zustandsautomaten, der für die Manöversegmentierung der zeitkontinuierlichen Messdaten eingesetzt wird. Rechteckige Blöcke stellen darin die Zustände dar, die entsprechend der farblichen Kennzeichnung auf drei Ebenen definiert sind. Auf der innersten Ebene (schwarz) befinden sich die in Abschnitt 6.2.1 definierten querdynamischen MS. In Form von Pfeilen sind die gerichteten Übergänge zwischen den Zuständen eingezeichnet, die entsprechend der Übergangsbedingung nummeriert sind. Findet auf einer übergeordneten Zustandsebene (hier grün oder blau) ein Zustandswechsel statt, dann wird der auf der darunterliegenden Ebene zutreffende Zustand von einem Initialpunkt aus bestimmt. In Abbildung A.1 sind die Initialpunkte als Rauten dargestellt.

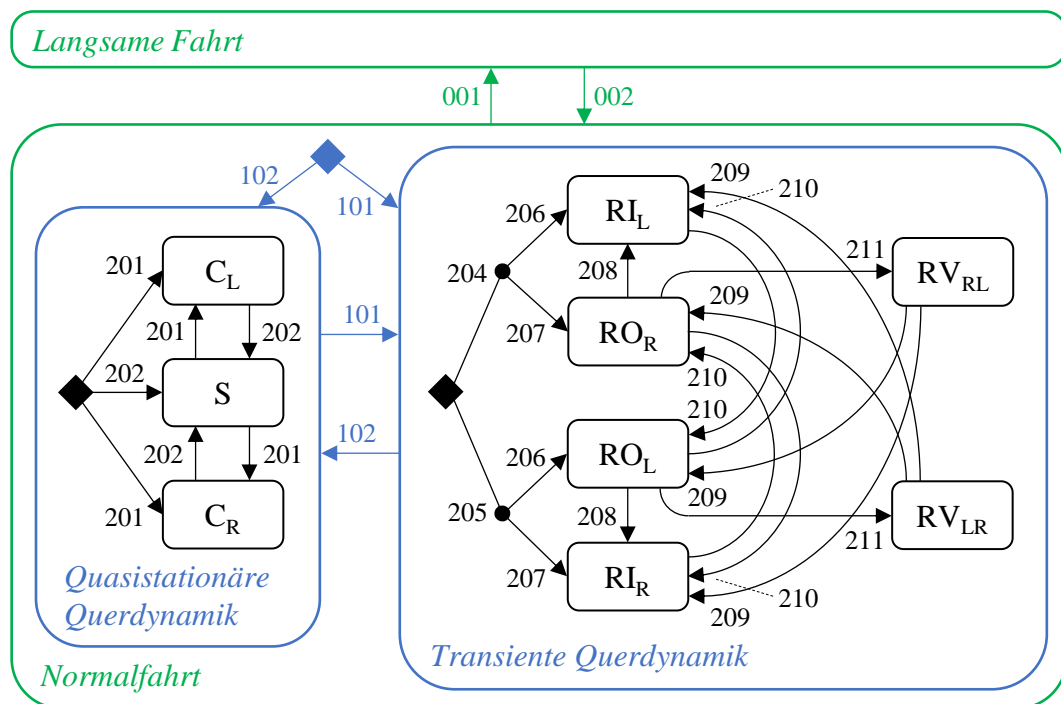


Abbildung A.1: Aufbau des Zustandsautomaten zur querdynamischen Manöversegmentierung.

Die nachfolgende Tabelle A.2 gibt Aufschluss über die Übergangsbedingungen, die sich hinter den Nummern in Abbildung A.1 verbergen. Darin stellen die Variablen G und H die Grenzwert- und Hysterese-Parameter dar, die zur Einstellung des Verhaltens der Manöversegmentierung angepasst werden. $\dot{\varphi}_m$ und $\ddot{\varphi}_m$ sind gleitende Mittelwerte der Rollrate und Rollbeschleunigung, deren Einstellung ebenfalls Parameter der Optimierung des Zustandsautomaten darstellen.

Nummer der Übergangsbedingung	Bedingung
001	$f(v_x, G_v, H_v)$
002	$f(v_x, G_v)$
101	$f(\phi, \dot{\phi}_m, \ddot{\phi}_m, G_\phi, H_\phi)$
102	$f(\dot{\phi}, \ddot{\phi}, G_\phi, G_{\ddot{\phi}}, H_\phi)$
201	$f(\phi, G_\phi)$
202	$f(\phi, G_\phi, H_\phi)$
204	$\text{sgn}(\dot{\phi}) = -1$
205	$\text{sgn}(\dot{\phi}) = 1$
206	$\text{sgn}(\phi) = -1$
207	$\text{sgn}(\phi) = 1$
208	$f(\phi, \dot{\phi}, \ddot{\phi}, G_\phi, G_{\ddot{\phi}}, H_\phi)$
209	$f(\phi, \dot{\phi}, G_\phi, G_{\ddot{\phi}}, H_\phi)$
210	$f(\dot{\phi}, G_\phi, H_\phi)$
211	$f(\phi, \dot{\phi}, \ddot{\phi}, G_{\phi,RV}, G_{\ddot{\phi},RV}, G_{\ddot{\phi}})$

Tabelle A.2: Übergangsbedingungen des Zustandsautomaten zur querdynamischen Manöversegmentierung.

A.6 Korrektur fehlerhaft klassifizierter Manöversegmente

Die Ausgabe des Zustandsautomaten zur Manöversegmentierung wird einer Korrekturroutine unterzogen, um die Güte der Klassifizierung zu erhöhen. Dazu werden die in Tabelle A.3 aufgeführten Typen unplausibler MS-Übergänge, Kriterien zu deren Erkennung und Korrekturen definiert. Die Abkürzungen für die MS wurden in Abschnitt 6.2.1 eingeführt. Wenn keine Indizes für die Richtung von MS angegeben sind, so wird das entsprechende Kriterium für alle möglichen Kombinationen von Richtungen abgeprüft.

Typ des Fehlers in der Manöversegmentierung	Kriterium: unplausible zeitliche Abfolge von Manöversegmenten	Korrektur: korrigierte zeitliche Abfolge von Manöversegmenten
Einrollbewegung zwischen MS der Geradeausfahrt	$S \Rightarrow RI \Rightarrow S(t \geq G_t)$	S
Unplausibel kurze Erkennung eines transienten MS während quasistationärer Kurvenfahrt	$C \Rightarrow RI(t < G_t) \Rightarrow C(t \geq G_t)$	C
	$C \Rightarrow RO(t < G_t) \Rightarrow C(t \geq G_t)$	C
Unplausibel kurze Erkennung eines quasistationären MS zwischen transienten MS	$RI \Rightarrow S(t < G_t) \Rightarrow RI(t \geq G_t)$	RI
	$RI \Rightarrow C(t < G_t) \Rightarrow RI(t \geq G_t)$	RI
	$RO \Rightarrow S(t < G_t) \Rightarrow RO(t \geq G_t)$	RO
	$RO \Rightarrow C(t < G_t) \Rightarrow RO(t \geq G_t)$	RO
Unplausible Erkennung eines Schräglagenwechsels	$RO \Rightarrow RV \Rightarrow S$	RO \Rightarrow S, Zeitdauer von RV wird RO zugeschlagen
	$RO_L \Rightarrow RV_{LR} \Rightarrow C_L$	RO _L \Rightarrow C _L , Zeitdauer von RV _{LR} wird RO _L zugeschlagen
	$RO_R \Rightarrow RV_{RL} \Rightarrow C_R$	RO _R \Rightarrow C _R , Zeitdauer von RV _{RL} wird RO _R zugeschlagen
	$RO_L \Rightarrow RV_{LR} \Rightarrow RI_L$	RO _L \Rightarrow RI _L , Zeitdauer von RV _{LR} wird RO _L zugeschlagen
	$RO_R \Rightarrow RV_{RL} \Rightarrow RI_R$	RO _R \Rightarrow RI _R , Zeitdauer von RV _{RL} wird RO _R zugeschlagen
Überschwingen der Rolldynamik am Kurvenausgang	$RO \Rightarrow RI \Rightarrow S(t \geq G_t)$	RO \Rightarrow S, Zeitdauer von RI wird S zugeschlagen
Überschwingen der Rolldynamik aus transientem Manöver in quasistationärer Kurvenfahrt	$RI \Rightarrow RO(t < G_t) \Rightarrow C(t \geq G_t)$	RI \Rightarrow C, Zeitdauer von RO wird C zugeschlagen
	$RO_L \Rightarrow RI_L(t < G_t) \Rightarrow C_L(t \geq G_t)$	RO _L \Rightarrow C _L , Zeitdauer von RI _L wird C _L zugeschlagen
	$RO_R \Rightarrow RI_R(t < G_t) \Rightarrow C_R(t \geq G_t)$	RO _R \Rightarrow C _R , Zeitdauer von RI _R wird C _R zugeschlagen

Tabelle A.3: Korrekturen logischer Fehler in der Manöversegmentierung: Typen, Kriterien und Korrekturen.

Teilweise beinhalten die Kriterien zur Korrektur der Manöversegmentierung eine zeitliche Bedingung in Abhängigkeit des Grenzwerts G_t , weil unterhalb einer bestimmten zeitlichen Dauer eines MS nicht mehr von einer bewussten Handlung des Fahrers (Fahrerabsicht) ausgegangen werden kann. Damit soll verhindert werden, dass Störungen der Fahrdynamik (z.B. durch Straßenanregung) oder unterbewusste Stabilisierungseingaben des Fahrers zur Änderung eines MS führen.

In der folgenden Aufzählung ist angegeben, wie häufig die verschiedenen Typen logischer Fehler in der Manöversegmentierung korrigiert werden, wenn die Kriterien aus Tabelle A.3 auf die gesamten Messdaten der Datenerhebung im Realverkehr aus Abschnitt 6.1 angewendet werden. Die relativen Häufigkeiten beziehen sich auf die Anzahl der übriggebliebenen und damit korrekten MS-Typen, die jeweils in Klammern angegeben sind.

- Unplausible Erkennung eines Schräglagenwechsels: 24,6 % (RV)
- Einrollbewegung zwischen MS der Geradeausfahrt: 13,8 % (RI)
- Überschwingen der Rolldynamik am Kurvenausgang: 4,2 % (RI)
- Unplausibel kurze Erkennung eines transienten MS während quasistationärer Kurvenfahrt: 2,7 % (RI und RO)
- Unplausibel kurze Erkennung eines quasistationären MS zwischen transienten MS: 1,9 % (RI und RO)
- Überschwingen der Rolldynamik aus transientem Manöver in quasistationärer Kurvenfahrt: 0,6 % (RI und RO)

Unplausible Schräglagenwechsel und fehlerhaft detektierte Einrollbewegungen sind mit Abstand die häufigsten Fehlklassifikationen, die durch den Zustandsautomaten gemacht werden. Dabei zeigt das Histogramm in Abbildung A.2, dass deutliche Unterschiede zwischen der Häufigkeit in den einzelnen Messfahrten vorliegen. Die einheitliche Parametrisierung des Zustandsautomaten funktioniert demnach nicht gleich gut für alle Fahrer. Insbesondere im Verhalten des Schräglagenaufbaus aus Geradeausfahrt und im Schräglagenwechsel liegen folgenreiche Unterschiede im Fahrerverhalten vor.




Abbildung A.2: Verteilung der Anteile falsch erkannter Schräglagenwechsel und Einrollbewegungen aus Geradeausfahrt über die einzelnen Messfahrten der Datenerhebung.

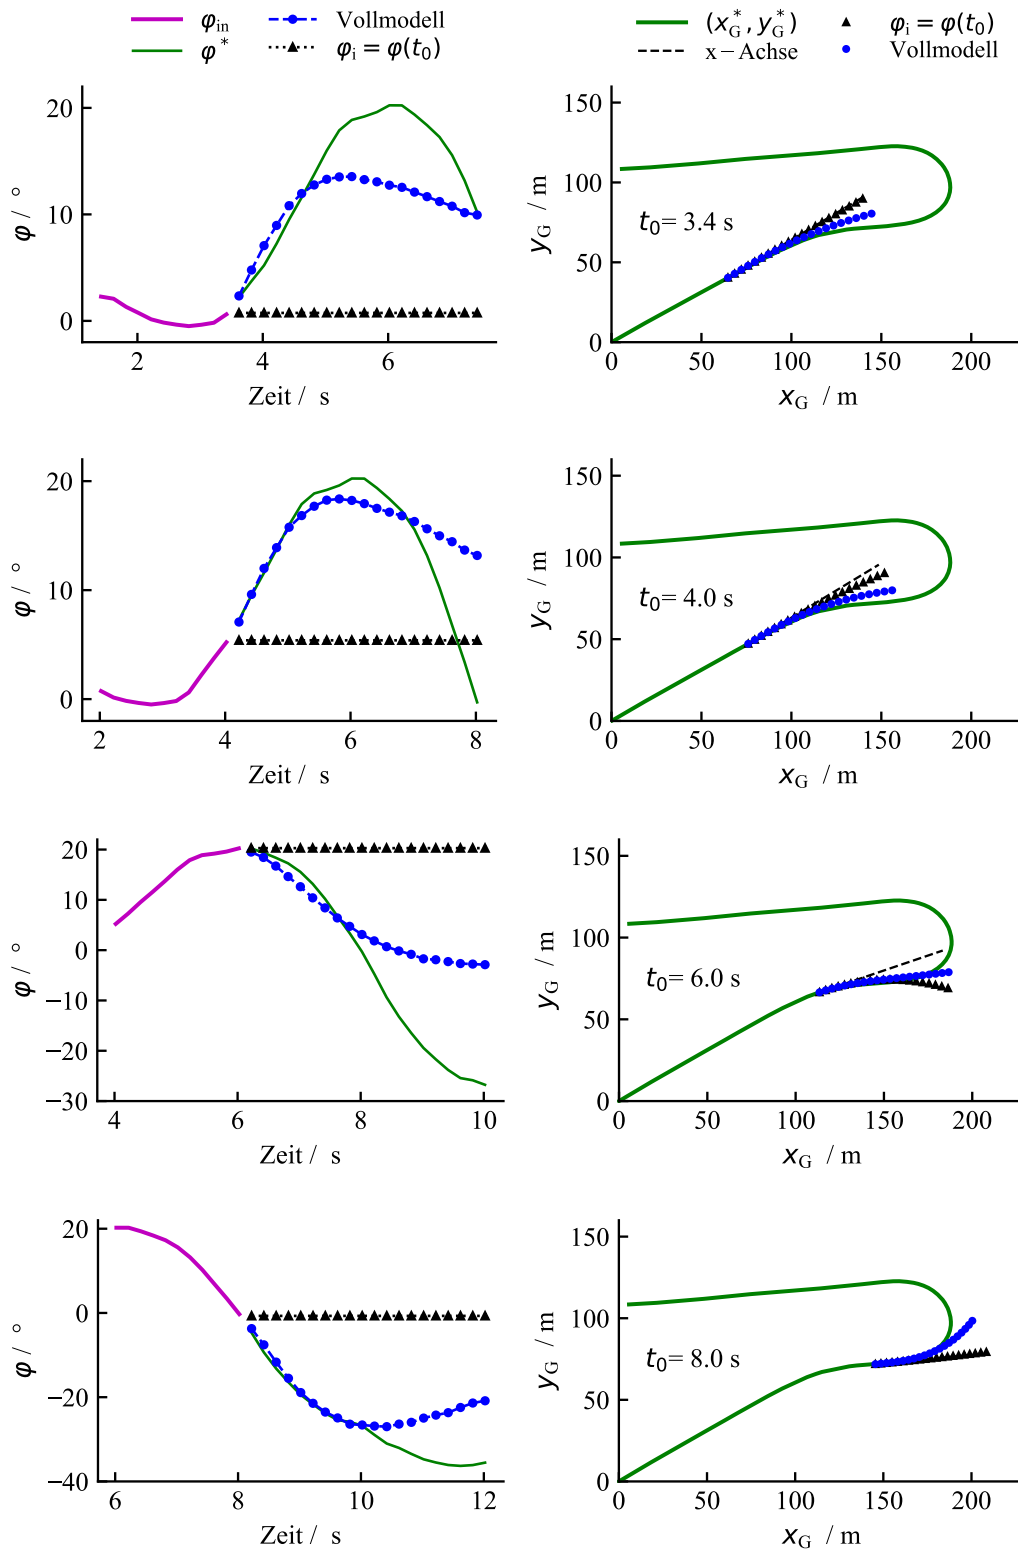
A.7 Konstante Parameter der Hyperparameteroptimierungen

Während der drei, in Abschnitt 7.4 beschriebenen, HP-Optimierungen mit Hilfe der Optuna-Software werden jeweils vier HP variiert. Die übrigen HP sind entsprechend der im folgenden notierten Werte konstant eingestellt.

- HP-Optimierung 1:
 - $n_{\text{In}} = 51$
 - $T_{\text{In}} = 0,1 \text{ s}$
 - $n_{\text{MLP}} = 2$
- HP-Optimierung 2:
 - $T_{\text{In}} = 0,1 \text{ s}$
 - $n_{\text{LSTM}} = 1$
 - $n_{\text{B}} = 2^9$
- HP-Optimierung 3:
 - $n_{\text{LSTM}} = 1$
 - $n_{\text{MLP}} = 2$
 - $n_{\text{B}} = 2^9$

A.8 Rollwinkel- und Positionsprädiktion in einem Beispielmanöver

Abbildung A.3 dient der Veranschaulichung von Rollwinkel- und Positionsprädiktionen am konkreten Beispiel einer Kurvenkombination, bestehend aus 30° Rechtskurve und anschließender 180° Linkskurve. Es sind mehrere Zeitpunkte des Manövers dargestellt.



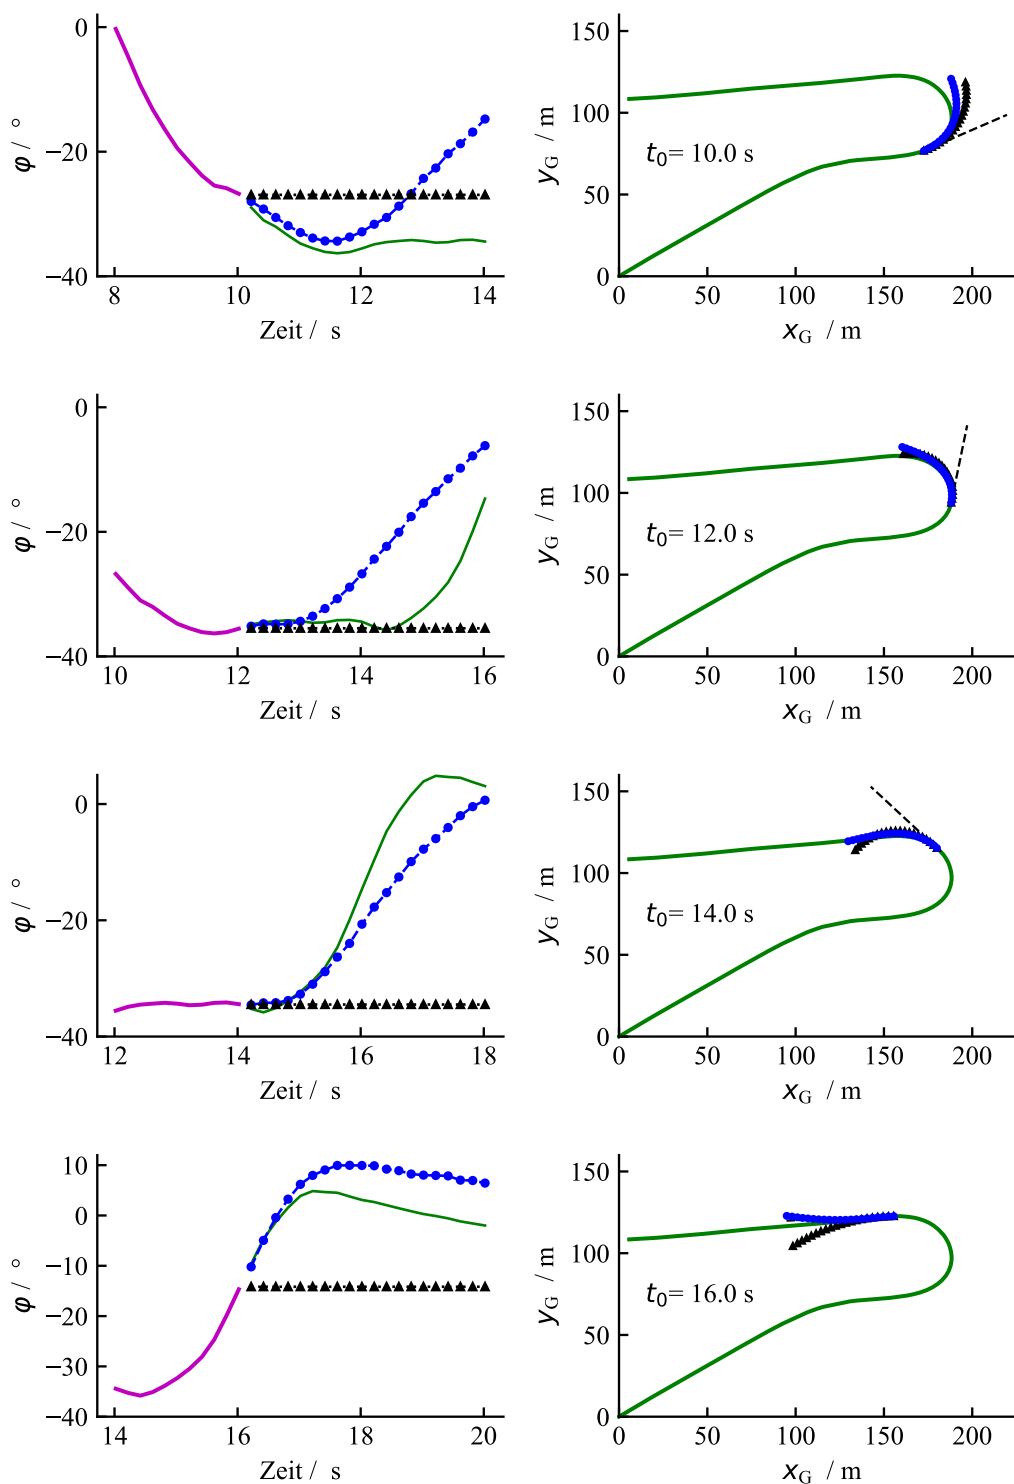


Abbildung A.3: Rollwinkelprädiktion von Vollmodell und Standardbewegungsmodell konstanter Kurvenfahrt sowie die daraus errechnete Positionsprädiktion für mehrere Zeitpunkte einer beispielhaften Fahrsituation: 30° Rechtskurve und daran anschließende enge 180° Linkskurve mit minimaler Kurvengeschwindigkeit von 43 km/h.

Die in den linken Diagrammen der Abbildung A.3 blau dargestellten Rollwinkeltrajektorien des Vollmodells sind teilweise glatter als die tatsächlichen Rollwinkelverläufe über dem Prädiktionshorizont in grün. Damit der Verlauf des Manövers besser ersichtlicher ist, stellen die rechten Diagramme die Positionstrajektorie in globalen Koordinaten (x_G , y_G) dar.

A.9 Manöversegmente im Testdatensatz nach Geschwindigkeitsbereichen

Der Testdatensatz, welcher, wie in Abschnitt 7.3 beschrieben, 7 % der Realfahrdaten aus der Datenerhebung enthält, wird auf die enthaltene Querdynamik untersucht. Dazu wird das Ergebnis der querdynamischen Manöversegmentierung in vier Geschwindigkeitsbereichen betrachtet, wobei für jedes Sample das MS und die Geschwindigkeit zum Zeitpunkt der Prädiktion t_0 ausgewertet werden. Abbildung A.4 zeigt in Kreisdiagrammen die Anteile der MS in den Testsamples der vier Geschwindigkeitsbereiche.

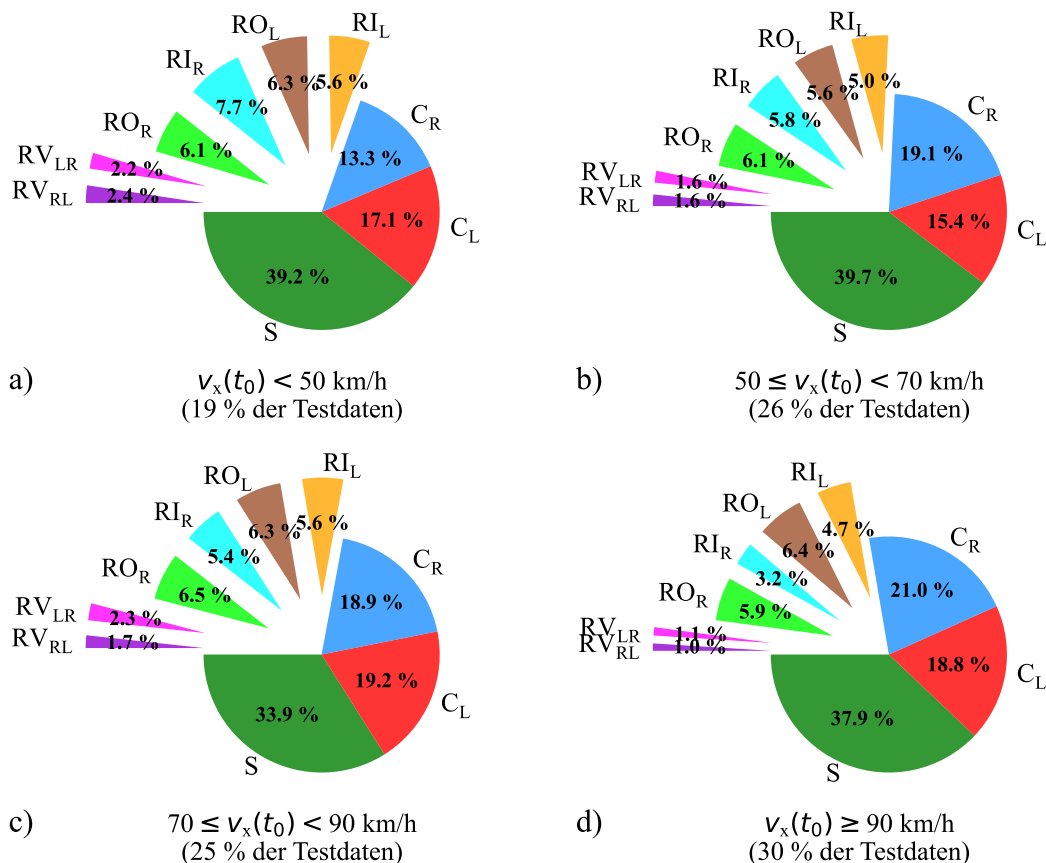


Abbildung A.4: Zeitliche Anteile querdynamischer MS in den Testdaten ausgewertet für unterschiedliche Geschwindigkeitsbereiche (Geschwindigkeit zum Zeitpunkt der Prädiktion).

Mit höherer Geschwindigkeit ist zunehmender Anteil stationärer Kurvenfahrt (C_R & C_L) zu erkennen. Der Anteil von Schräglagenaufbau-MS (R_I_R & R_I_L) ist für Geschwindigkeiten kleiner 50 km/h am größten und bei mehr als 90 km/h am geringsten, dazwischen ist er konstant. Schräglagenabbau-MS (R_O_R & R_O_L) treten hingegen in allen vier betrachteten Geschwindigkeitsbereichen annähernd gleich häufig auf; für den Bereich größer 90 km/h ist dies nicht verwunderlich, weil am Kurvenausgang während der Aufrichtbewegung meist gleichzeitig beschleunigt wird. Schräglagenwechsel-MS (R_V_{RL} & R_V_{LR}) treten häufiger im Bereich kleiner 50 km/h und zwischen 70 und 90 km/h auf, hingegen mit Abstand am seltensten bei mehr als 90 km/h; die vergleichsweise geringere Häufigkeit zwischen 50 und 70 km/h

könnte z.B. darin begründet sein, dass hier mehr Kurvenfahrten mit niedriger Rolldynamik enthalten sind – im Fall von Kurvenkombinationen wird dann weniger häufig der Schräglagenwechsel klassifiziert.