
Masterarbeit

zur Erlangung des Grades
Master of Science (M.Sc.)
im Studiengang Human-Computer Interaction
an der Universität Würzburg

Untersuchung der Linienwahl von Motorradfahrern

vorgelegt von
Oliver Krauß
Matrikelnummer: 2543906

am 24. Februar 2025

Erstgutachter:
Dr. habil. Tobias Grundgeiger, Psychologische Ergonomie
Zweitgutachter:
Dr. Sebastian Will, Psychologische Methoden, Kognition und
Anwendung
Universität Würzburg

Danksagung

An dieser Stelle möchte ich mich herzlich bei all jenen bedanken, die mich während der Erstellung dieser Abschlussarbeit unterstützt, motiviert und begleitet haben.

Mein herzlicher Dank gilt meinem Erstgutachter Dr. Tobias Grundgeiger, der durch seine Bereitschaft diese Arbeit zu begleiten, ihre Durchführung überhaupt erst ermöglicht hat.

Insbesondere danke ich ihm für seine außergewöhnliche Unterstützung und engagierte Beratung, bereits vor dem Beginn meines Masterstudiums, welche mich maßgeblich zum Wechsel in den HCI-Studiengang motiviert hat.

Ganz besonders danken möchte ich meinem Zweitgutachter Dr. Sebastian Will, für seine engagierte Betreuung, die wertvollen fachlichen Hinweise und die stets konstruktiven Diskussionen, die entscheidend zum Gelingen dieser Arbeit beigetragen haben. Der mich mit viel Geduld und stets motivierenden Worten immer wieder angespornt hat und meinen akademischen Weg über viele Jahre hinweg begleitet und maßgeblich geprägt hat.

Vielen Dank an die Experten für ihre Bereitschaft zur Teilnahme an den Interviews und die zahlreichen, wertvollen Anregungen auf meinem Weg zur Hypothesenbildung.

Ein herzliches Dankeschön gilt auch meinen Kolleginnen und Kollegen am Würzburger Institut für Verkehrswissenschaften (WIVW), die mich durch ihren fachlichen Austausch, ihre Hilfsbereitschaft und ihre freundschaftliche Atmosphäre stets unterstützt haben. Im Besonderen Dr. Raphael Pless, für seine Unterstützung bei der Erstellung der Datensätze und die zahlreichen, wertvollen Diskussion an der Kaffeemaschine.

Ein weiterer großer Dank geht an meinen Stipendiengeber, die Stiftung Begabtenförderung berufliche Bildung (SBB), für die großzügige finanzielle Unterstützung, die mein Studium überhaupt erst ermöglicht hat.

Abschließend möchte ich mich bei all jenen bedanken, die auf unterschiedliche Weise zum Gelingen dieser Arbeit beigetragen und mir während dieser intensiven Zeit den Rücken gestärkt haben.

Vielen Dank!

Zusammenfassung

Die vorliegende Arbeit untersucht die Linienwahl von Motorradfahrern in Kurven und analysiert, welche Faktoren die Positionierung im Fahrstreifen beeinflussen und wie sich dies auf die Sicherheit auswirkt. Hintergrund der Untersuchung ist die hohe Unfallrate von Motorradfahrern, insbesondere in Kurven, die häufig auf Fahrfehler zurückzuführen sind. Mithilfe eines sog. Naturalistic Riding Study-Ansatzes wurden reale Fahrdaten von $N = 37$ Probanden über eine 124 km lange Teststrecke erfasst. Die Analyse basiert auf einer Kombination aus GPS- und Videodaten, die durch moderne Bildverarbeitungsmethoden und Machine-Learning-Ansätze ausgewertet wurden.

Die Ergebnisse zeigen, dass vor allem die Einsehbarkeit der Kurve, die Fahrgeschwindigkeit und das Vorhandensein von Gegenverkehr einen signifikanten Einfluss auf die Linienwahl haben. Fahrer tendieren dazu, sich in schlecht einsehbaren Kurven und mit zunehmender Fahrgeschwindigkeit weiter von der Straßenmitte zu entfernen. Darüber hinaus konnte festgestellt werden, dass individuelle Fahrstile eine erhebliche Rolle spielen. Die gewonnenen Erkenntnisse liefern wertvolle Hinweise für die Entwicklung von Assistenzsystemen und Maßnahmen zur Erhöhung der Verkehrssicherheit.

Abstract

This study investigates the lane positioning of motorcyclists in curves and analyzes which factors influence the trajectory choices and how this affects safety. The background of this research is the high accident rate among motorcyclists, particularly in curves, where rider errors are a frequent cause. Using a so called Naturalistic Riding Study approach, real-world riding data from $N = 37$ participants was collected over a 124 km test route. The analysis combines GPS and video data, evaluated through modern image processing techniques and machine learning methods.

The results indicate that the visibility of the curve, riding speed, and the presence of oncoming traffic significantly impact trajectory choice. Riders tend to position themselves farther from the center of the road in poorly visible curves and with increasing speed. Additionally, individual riding styles play a substantial role. These findings provide valuable insights for the development of rider assistance systems and measures to enhance road safety.

Inhaltsverzeichnis

| | |
|--|-----------|
| Abbildungsverzeichnis | ix |
| Tabellenverzeichnis | xi |
| 1 Einleitung | 1 |
| 2 Theoretische Grundlagen | 3 |
| 2.1 Linienwahl und Trajektorienplanung | 3 |
| 2.2 Fahrerhaltensmodelle | 4 |
| 2.3 Untersuchung von Fahrerverhalten | 6 |
| 3 Methodik | 9 |
| 3.1 Datensatz | 9 |
| 3.1.1 Stichprobe | 9 |
| 3.1.2 Fahrtstrecke | 10 |
| 3.1.3 Messtechnik | 10 |
| 3.2 Experteninterviews | 11 |
| 3.3 Prädiktorenauswahl und Hypothesengenerierung | 15 |
| 3.4 Statistische Auswertung | 17 |
| 4 Ergebnisse | 19 |
| 4.1 Postprocessing | 19 |
| 4.1.1 Framework | 19 |
| 4.1.2 Maptool | 21 |
| 4.1.3 Videodaten | 22 |
| 4.1.4 Ermittlung des Querversatz | 23 |
| 4.2 Deskriptive Datenanalyse | 31 |
| 4.3 Inferenzstatistische Datenanalyse | 38 |
| 5 Diskussion | 41 |
| Literatur | 45 |
| Anhang | 48 |

Abbildungsverzeichnis

| | | |
|------|---|----|
| 2.1 | Risikohomöostase-Theorie | 5 |
| 3.1 | Fahrtstrecke Taubertal | 10 |
| 3.2 | Messmotorrad KTM Duke (WIVW GmbH) | 11 |
| 4.1 | UML-Diagramm DataLoader | 19 |
| 4.2 | UML-Diagramm VideoPlayer | 20 |
| 4.3 | UML-Diagramm FrameAnnotator | 20 |
| 4.4 | UML-Diagramm TrackLoader | 21 |
| 4.5 | UI Maptool | 21 |
| 4.6 | Beispiel Videoframe | 23 |
| 4.7 | Aufbau CLRnet | 25 |
| 4.8 | Beispiel CLRnet prediction mit rechtem Fahrbahnrand (gelb), linkem (grün) und Mittelstreifen (magenta) | 26 |
| 4.9 | Kartendarstellung der selektierten Kurven mit Umschlingungswinkeln (rot) | 27 |
| 4.10 | Definition Kurvenabschnitte | 28 |
| 4.11 | Datenclustering vorher/nachher | 29 |
| 4.12 | Berechnung Querversatz: Fahrbahnmarkierungen (gelb), Ego-Punkt (türkis), Fahrstreifenbreite (grün), Abstand zum rechten Fahrbahnrand (blau) | 30 |
| 4.13 | Histogramm Querversatz (links) und Boxplot Querversatz nach Kurvenabschnitt (rechts) | 31 |
| 4.14 | Boxplot Querversatz nach Kurvenradius und Umschlingungswinkel | 32 |
| 4.15 | Boxplot Fahrgeschwindigkeit über Kurvenabschnitt | 32 |
| 4.16 | Scatterplot Querversatz am Scheitelpunkt über Fahrgeschwindigkeit (links) und Rollwinkel (rechts) | 33 |
| 4.17 | Boxplot Querversatz nach Versuchsperson | 33 |
| 4.18 | Individueller Querversatz nach Kurve | 34 |
| 4.19 | Verteilung der Gradient-Kategorien | 35 |
| 4.20 | Gradient-Kategorien nach Versuchspersonen | 36 |
| 4.21 | Histogramm krit.Querversatz (links) und Anzahl krit.Querversatz nach Kurvenabschnitt | 36 |

Tabellenverzeichnis

| | | |
|-----|---|----|
| 4.1 | Tabelle Kurvenparameter | 27 |
| 4.2 | Deskriptive Statistiken AV | 31 |
| 4.3 | Ergebnisse der multiplen linearen Regression AV: Querversatz | 38 |
| 4.4 | Ergebnisse der multiplen linearen Regression AV: krit.Querversatz . . | 39 |
| B.1 | Tabelle Kurvenparameter | 53 |
| C.1 | Tabelle Ausschlüsse | 55 |

1 Einleitung

In Anbetracht der Herausforderungen durch die emissionsbedingte Klimaerwärmung und die stetig steigende Weltbevölkerung, stellt das Motorrad für den Individualverkehr eine umweltfreundlichere Alternative zum Pkw dar. Seine kompaktere Bauweise ermöglicht eine effizientere Nutzung des Verkehrsraums, sowohl im fließenden, als auch im ruhenden Verkehr (World Health Organization, [2022](#)). So könnten Staus mit erhöhtem Emissionsaufkommen reduziert werden und versiegelte Parkflächen könnten klimafreundlich begrünten Parkanlagen weichen (Vasic & Weilenmann, [2006](#)). Auch in Bezug auf den Ressourcenaufwand in der Fertigung stellt das Motorrad die ökonomischere und nachhaltigere Alternative dar (Eccarius & Lu, [2020](#)).

Neben allen Vorteilen verdeutlicht jedoch ein Blick auf die Unfallzahlen, dass im Hinblick auf die Verkehrssicherheit von Motorradfahrern noch dringender Handlungsbedarf besteht. So ist laut Statistisches Bundesamt, [2023](#) das Risiko für einen Motorradfahrer im Zuge eines Verkehrsunfalls verletzt zu werden etwa doppelt und getötet zu werden gar fünfmal höher als für den Insassen eines Pkw (pro Anzahl zugelassener Fahrzeuge - bestandsbezogenes Risiko). Wohingegen durch intensive Bestrebungen in Forschung und Entwicklung die Zahl der schwer- und tödlich verunglückten Autofahrer in den letzten Jahrzehnten stetig reduziert werden konnte, verharrt die Zahl der Motorradfahrer auf konstant hohem Niveau (Statistisches Bundesamt, [2021](#)).

Angesichts der generell höheren Vulnerabilität des Motorradfahrers - der über keine schützende Karosserie verfügt - mag ein höheres Verletzungsrisiko im Falle eines Unfalls inhärent anmuten und vergleichsweise wenig Potential für technologische Verbesserungen im Bereich der passiven Sicherheit bieten. Aus diesem Grund stellt die Prävention, in Form der Vermeidung von Unfällen eine weitaus wichtigere Schraube dar. Aus der Analyse von Unfalldaten geht hervor, dass es sich bei einem Drittel aller Motorradunfälle um Alleinunfälle - d.h. ohne Beteiligung weiterer Verkehrsteilnehmer - handelt, bei welchen die Fahrer häufig auf kurvigen Abschnitten die Kontrolle über ihr Fahrzeug verlieren, stürzen und/oder von der Straße abkommen. Mehrere Quellen benennen dabei einen Fahrfehler als die häufigste Unfallur-

sache (ADAC e.V., 2023, Bundesanstalt für Straßenwesen, 2021, Center for Urban Transportation Research CUTR, 2018, Winkelbauer et al., 2017, Özkan et al., 2012, Wyss et al., 2009), darunter wird ein falsches bzw. unangepasstes Handeln des Fahrzeugführers verstanden.

Das Durchfahren einer Kurve mit einem Motorrad stellt eine hochkomplexe Aufgabe dar, da Kurvenparameter innerhalb kürzester Zeit abgeschätzt und Fahrgeschwindigkeit, sowie Schräglage entsprechend angepasst werden müssen. Durch die Fahrphysik des Motorrads stehen Fahrgeschwindigkeit, Schräglage und Kurvenradius in mathematischem Zusammenhang. Aufgrund der geringen Fahrzeugbreite eines Motorrads im Vergleich zur Breite des Fahrstreifens, entsteht ein gewisser Gestaltungsraum für den Fahrer, seine Trajektorie im Rahmen des baulich vorgegebenen Kurvenverlaufs zu platzieren. Mit der Wahl seiner Trajektorie (fort folgend Linie) genannt, ist es dem Fahrer möglich den Kurvenradius zu variieren und durch eine alternative Platzierung des Scheitelpunkts die Einsicht in die Kurve entscheidend zu beeinflussen. Somit stellt die Linienwahl einen maßgeblichen Sicherheitsfaktor dar und Fehlentscheidungen bergen hohes Gefahrenpotential. Untersuchungen diesbezüglich berichten von 36% (Lemonakis, 2021) bzw. gar 95% (Winkelbauer & Bagar, 2013) gewählter Linien, welche mit einem erhöhten Unfallrisiko einhergehen. Eine Verhaltensanpassung durch bauliche Maßnahmen in Form von zusätzlichen Fahrbahnmarkierungen zeigten gute Ergebnisse (Pettrisch und Kemper, 2024, Winkelbauer et al., 2018), sind jedoch auf den Einsatz an z.B. Unfallschwerpunkten beschränkt. Es liegen bisher keine Forschungsergebnisse zu Ursachen bzw. Prädiktoren einer unsicheren Linienwahl vor, um ggf. Interventionen mit höherer Reichweite und damit größerem Effekt ableiten zu können. Diese Lücke soll die vorliegende Arbeit schließen.

Eine weitere Motivation betrifft Entwicklungen im Bereich der aktiven Sicherheit, welche den Fokus hat, den Fahrer in kritischen Situationen durch Fahrerassistenzsysteme (ADAS) zu unterstützen und damit die Entstehung von Unfällen zu vermeiden. Eine zentrale Rolle spielt dabei die Fahrererverhaltensmodellierung, da sie es ermöglicht, das Verhalten des Fahrers in kritischen Verkehrssituationen realistisch vorherzusagen und die Assistenzsysteme so zu gestalten, dass sie proaktiv und situationsgerecht eingreifen können. Ein derart umfassendes und generalisierbares Verhaltensmodell ist bislang noch nicht verfügbar, da das Fahrerverhalten von einer Vielzahl individueller, situativer und kontextueller Faktoren beeinflusst wird, dessen Modellierung eine komplexe Herausforderung darstellt. Diese Arbeit soll einen Beitrag durch die Erklärung der Linienwahl in Kurven leisten.

2 Theoretische Grundlagen

2.1 Linienwahl und Trajektorienplanung

Betrachtet man den literarischen Kontext des Themas „Linienwahl von Motorradfahrern im Straßenverkehr“, findet sich reichlich populärwissenschaftliche Literatur in Form von Fachzeitschrift-Artikeln und Ratgebern mit praxisorientiertem, normativem Ansatz. Ebenso existieren wissenschaftlich fundierte Arbeiten (vgl. Angermann und Schwabe, 2018) zu den Sicherheitsaspekten unterschiedlicher Kurvenlinien und dem Stand der Fahrausbildung diesbezüglich. Darüber hinaus finden sich deskriptive, empirische Studien (Winkelbauer et al., 2019, Lemonakis, 2021), die belegen, dass die Trajektorien von Motorradfahrern signifikant vom tatsächlichen Kurvenverlauf abweichen, was unter anderem auch sicherheitskritische Implikationen nach sich zieht. Es wird berichtet, dass speziell Linkskurven oft „zu eng“ angefahren werden, d.h. die gewählte Trajektorie zu nah an der Mittellinie platziert wird, woraus folgt, dass nach Einleitung der Schräglage kein ausreichender Abstand des Oberkörpers zum Gegenverkehr mehr gegeben ist. Des Weiteren berichten die wissenschaftlichen Arbeiten von Pettrisch und Kemper, 2024, sowie Winkelbauer et al., 2018 von erfolgreichen Verhaltensanpassungen durch zusätzliche Fahrbahnmarkierungen diesbezüglich. Eine systematische Untersuchung der Linienwahl von Motorradfahrern, mit dem Ziel das beobachtete Verhalten erklären zu können, stellt jedoch bislang eine Forschungslücke dar.

Verallgemeinert man die Fragestellung „Wie bewegen sich Menschen von A nach B?“ finden sich interessante, neurowissenschaftliche Befunde zur ursprünglichsten Art der menschlichen Fortbewegung: Der Lokomotion. So zeigen die Trajektorien von Probanden, welche angewiesen wurden von ihrem Startpunkt zu unterschiedlichen End-Toren zu gehen, konsistente räumliche und zeitliche Merkmale (Hicheur et al., 2007). Des Weiteren entsprechen die beobachteten Pfade auch bei variierender Krümmung durch unterschiedliche Stellungen des End-Tors annähernd dem direkten

Weg, was auf evolutionär ausgebildete, energieökonomische Invariate in der Bewegungsplanung hindeutet (Todorov, 2004). Die Annahme einer generellen Tendenz kurze Wege zu bevorzugen, deckt sich mit der Erkenntnis aus Studien zum Kurven-Fahrverhalten von Autofahrern, welche aufzeigen, dass „Kurven schneiden“ ein häufig beobachtetes, typisches Fahrmuster darstellt (Yu et al., 2021, Xu et al., 2018) bzw. die laterale Positionierung des Fahrzeugs in Kurven signifikant zur Kurvenmitte hin tendiert (Das et al., 2016, Jacob und Violette, 2012, Bella, 2005, Spacek, 2005). Winkelbauer, 2022, Winkelbauer und Bagar, 2013 und Ibrahim et al., 2018 bestätigen diese Ergebnisse explizit für Motorradfahrer.

Die Annahme einer generellen, menschlichen Tendenz den kürzesten und damit vermeintlich energieeffizientesten Weg zu wählen, deckt sich mit den Ergebnissen der Experteninterviews in 3.2. Dieser Ansatz wird in Kap.5 weiter diskutiert.

2.2 Fahrerhaltensmodelle

Die Modellierung von Fahrerverhalten ist ein zentraler Bestandteil der Verkehrspsychologie und Fahrzeugsystementwicklung. Sie bietet Einblicke in die komplexen Interaktionen zwischen Fahrern, Fahrzeugen und ihrer Umgebung, indem sie unterschiedliche Ansätze zur Analyse und Simulation des Verhaltens nutzt. Eine systematische Klassifikation von Michon, 1985 unterscheidet Modelle nach ihrem Fokus auf beobachtbares Verhalten (Input-Output) oder interne Zustände (motivationsorientiert) sowie nach ihrer statischen (taxonomischen) oder dynamischen (funktionalen) Natur. Taxonomische Modelle wie Task-Analysen beschreiben detailliert die Anforderungen und Sequenzen von Fahraufgaben, während funktionale mechanistische Modelle Steuerungsprozesse dynamisch simulieren. Motivationsorientierte Trait-Modelle hingegen ordnen Fahrer aufgrund von Persönlichkeitsmerkmalen in Kategorien ein, während kognitive Prozessmodelle, wie die Risikohomöostasetheorie nach G. J. Wilde, 1998, dynamische Anpassungen des Fahrverhaltens auf Basis subjektiver Risikowahrnehmungen erklären.

Aufgrund der spezifischen Limitationen der anderen Modellkategorien, speziell in Bezug auf die Berücksichtigung kognitiver Zustände, sowie die Integration von Lernprozessen, stellen die kognitiven Prozessmodelle für die Erklärung der Linienwahl anhand zugrundeliegender Prädiktoren die beste Wahl dar.

Risikohomöostase-Theorie

Die Risikohomöostase-Theorie (Risk-Homeostasis-Theory, kurz RHT) nach G. J. Wilde, 1998 beschreibt menschliches Verhalten als Regelkreis mit einem persönlichen Zielrisikoniveau als Führungsgröße, ähnlich den Grundgedanken der Kybernetik (vgl. Abb. 2.1). Sie postuliert, dass Individuen ein Zielrisikoniveau haben, das sie akzeptieren, um einen optimalen Nutzen aus ihrem Verhalten zu ziehen.

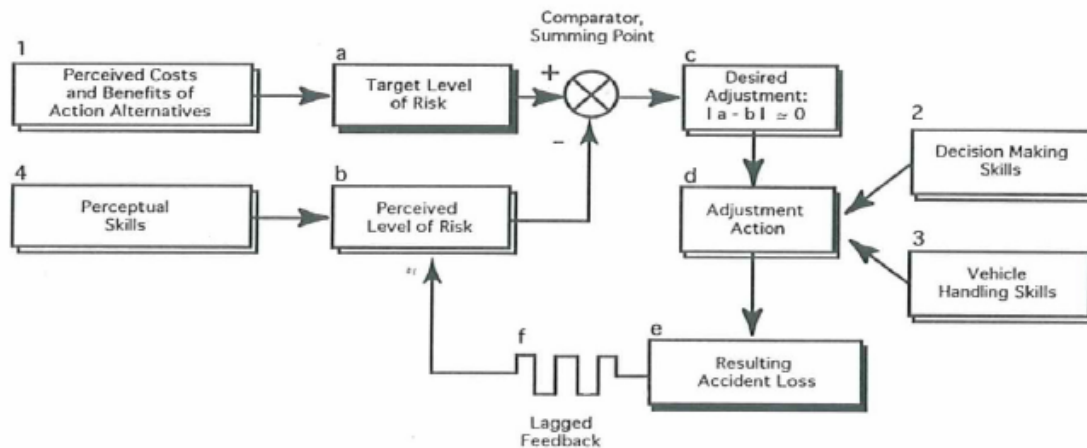


Abbildung 2.1. Risikohomöostase-Theorie

Vaa, 2007, S. 3

Verhaltensalternativen werden im Hinblick auf ihre risikobezogenen Kosten/Nutzen subjektiv bewertet, woraus sich ein persönliches Zielrisiko ergibt. Ein Risikoniveau, das das Individuum bereit ist in Kauf zu nehmen. Das tatsächlich wahrgenommene Risiko ergibt sich aus den (subjektiven) Fähigkeiten und wird stets mit dem Zielrisiko verglichen, um daraus Verhaltensanpassungen abzuleiten, welche das gewünschte Zielrisikoniveau wiederherstellen. Ist das wahrgenommene Risiko höher als gewünscht, wird das Verhalten vorsichtiger (z.B. Reduktion der Fahrgeschwindigkeit). Ist das wahrgenommene Risiko niedriger, wird das Verhalten riskanter (z.B. Fahrgeschwindigkeit steigern oder Aufmerksamkeitsabzug).

Sie beschreibt sehr gut in Bezug auf Sicherheitsmaßnahmen beobachtete, kompensatorische Verhaltensänderungen. Empirische Befunde deuten darauf hin, dass eingeführte Sicherheitsmaßnahmen (z.B. Sicherheitsgurt oder Antiblockiersystem) nur marginalen Effekt auf die Unfallraten zeigten, da Fahrer kompensatorisch zu risikoreicherem Fahrverhalten tendierten (G. J. S. Wilde, 1982). Die Implikation, dass

technologische oder infrastrukturelle Maßnahmen zur Verbesserung der Verkehrssicherheit alleine nicht ausreichen, sondern das Zielrisiko der Verkehrsteilnehmer mitbedacht werden muss, stellt eine wichtige Erkenntnis im Kontext sicherheitsverbessernder Initiativen dar. Auch abseits der Verkehrspsychologie ist die RHT eine einflussreiche Theorie und findet domänenübergreifend Anwendung, z.B. in Bezug auf gesundheitsbezogene Verhaltensweisen wie Rauchen oder übermäßiges Essen (Trimpop, 1996).

G. J. S. Wilde, 1982 postuliert, dass dem Verhalten von Individuen eine Kosten-/Nutzenfunktion mit vier zentralen Faktoren zugrunde liegt:

- Wahrgenommener Nutzen riskanten Verhaltens
- Wahrgenommene Kosten riskanten Verhaltens
- Wahrgenommene Kosten vorsichtigen Verhaltens
- Wahrgenommener Nutzen vorsichtigen Verhaltens

In Anbetracht dessen, dass eine „riskante“ Verhaltensalternative definitionsbedingt immer auch mit einer „vorsichtigen“ Verhaltensalternative einher gehen muss, bietet sich eine Verhaltensbewertung auf Basis der beiden Kontinuen Kosten/Nutzen, sowie Sicherheit/Risiko an.

Eine Erklärung der Linienwahl von Motorradfahrern anhand der RHT legt demnach eine Kostenfunktion zugrunde. Die tatsächlich gewählte Linie stellt eine Summe aus risikoreduzierenden und risikoe erhöhenden Verhaltensalternativen dar, welche zum angestrebten Zielrisiko tendiert. Die Bewertung der Verhaltensalternativen basiert dabei auf subjektiven Einschätzungen analog der Erwartung-mal-Wert-Theorie, welche neben der Gewichtung auch eine Auftretenswahrscheinlichkeit berücksichtigt.

2.3 Untersuchung von Fahrerverhalten

In seiner Arbeit zur Untersuchung von sicherheitskritischem Fahrerverhalten nennt Bärghman, 2016 als Ergebnis der Literaturrecherche vier unterschiedliche Ansätze zur Datengewinnung. Erstens die Analyse von Unfallberichten, zweitens die Erhebung von selbstberichteten Daten in Form von Fragebögen, drittens das experimentelle Setting z.B. in Form von Untersuchungen im Fahrsimulator und viertens der Datengewinnung im naturalistischen Fahrversuch.

Da sich die Analyse von Unfallberichten auf kritische Ereignisse beschränkt, stellt sie kein alleiniges Mittel zur Modellierung von Fahrerverhalten dar. Eine Datenerhebung auf Basis von Fragebögen setzt voraus, dass dem Verhalten zugrundeliegende Motive stets bewusst wären, wovon im Falle der Linienwahl nicht ausgegangen werden kann. Im Vergleich zu kontrollierten Experimental-Settings im Fahrsimulator ermöglicht eine naturalistische Fahrstudie detaillierte Einblicke ins Fahrerverhalten „in vivo“ und geht somit mit einer hohen externen Validität einher. In Anbetracht der limitierten Abbildungsqualität von Motorrad-Fahrsimulatoren, speziell in Bezug auf Querkräfte, müsste davon ausgegangen werden, dass das gezeigte Verhalten von dem im realen Fahrbetrieb erheblich differiert. Aus diesem Grund wurde die Auswertung von Realfahrdaten zur Untersuchung der Linienwahl von Motorradfahrern gewählt.

Naturalistische Fahrstudien - Naturalistic Riding Studies

Naturalistic Riding Studies (kurz NRS) - bzw. Naturalistic Driving Studies, im allgemeinen Kontext - sind eine Methode zur Datengewinnung in der Verkehrspsychologie, welche durch den Einsatz von messtechnisch instrumentierten Fahrzeugen die Untersuchung von Fahrverhalten in realen Umgebungen ermöglicht. Typischerweise werden dabei Fahrzeuge möglichst unauffällig mit umfangreicher Messtechnik zur Erfassung von Sensor- und Videodaten ausgestattet und Probanden über längere Zeiträume zur Nutzung überlassen. Dabei werden große Datenmengen gesammelt, welche eine umfangreiche Analyse ermöglichen, um Risikofaktoren, Verhaltensmuster und Umwelteinflüsse zu identifizieren (Klauer et al., [2011](#)).

Gerade explorative Untersuchungen profitieren von der umfangreichen Datenmenge und sind im Hinblick auf ihre inferenzstatistische Aussagekraft auf eine möglichst hohe Stichprobengröße angewiesen. Aus diesem Grunde eignet sich der vorliegende Datensatz aus einer NRS ideal für die zu untersuchende Fragestellung.

3 Methodik

3.1 Datensatz

Der der Untersuchung zugrundeliegende Datensatz wurde im Zuge des Projekts KI-MoVe im Rahmen des ZIM (Zentrales Innovationsprogramm Mittelstand) des Bundesministeriums für Wirtschaft und Klimaschutz geförderten Forschungsprojekts erstellt. Ziel des Projekts ist es, mithilfe KI-basierter Auswertung von Realfahrdaten ein tieferes Verständnis für das Verhalten von Motorradfahrern zu erlangen, um daraus ein Fahrerverhaltensmodell ableiten zu können.

Der Datensatz umfasst Realfahrdaten eines Streckenabschnitts im Großraum Tauberfranken, welche von Probanden mit einem mit Messtechnik ausgestatteten Motorrad absolviert wurde. Die Probanden wurden instruiert, der vorgeladenen Route auf dem Navigationssystem zu folgen und „so wie immer“ zu fahren.

3.1.1 Stichprobe

Die untersuchte Stichprobe bestand aus $N = 37$ Motorradfahrern (35 Männer, 2 Frauen), welche aus dem Probanden-Panel des WIVW akquiriert wurden. Alle Fahrer waren im Besitz der Fahrerlaubnis Klasse A. Das Alter lag im Mittel bei $M = 45$ Jahren ($SD = 14$ Jahre). Die durchschnittliche Motorrad-Fahrerfahrung betrug $M = 127\,041$ km ($SD = 157\,654$ km), bezogen auf die letzten 12 Monate $M = 6\,341$ km ($SD = 6\,704$ km).

Aufgrund von temporären Streckensperrungen, Ausfällen der Messtechnik oder einzelner Ausschlüsse aufgrund schlechter Detektionsergebnisse, wurden nicht von allen Probanden vollständige Datenreihen berücksichtigt. Eine Liste der Ausschlüsse findet sich im Anhang 5.

3.1.2 Fahrtstrecke



Abbildung 3.1. Fahrtstrecke Taubertal

Das Fahrprofil der in Abb. 3.1 dargestellten, 124 km langen Strecke umfasste Stadt-, Landstraßen- und Autobahnabschnitte. Start- und Endpunkt war der Standort der WIVW GmbH in Veitshöchheim. Die Fahrtdauer betrug ca. 2 h.

3.1.3 Messtechnik

Alle Probanden absolvierten die Fahrt mit einem zu diesem Zweck vom WIVW (Würzburger Institut für Verkehrswissenschaften GmbH) bereitgestellten Mess-Motorrad des Fabrikats KTM Duke 790 Baujahr 2019 (Abb. 3.2). Neben dem CAN-Bus-Abgriff von Fahrzeugsignalen wie Gasgriffstellung, Bremsschalter und IMU-Daten (Inertial Measurement Unit) wurden GPS-Positionsdaten erfasst. Die Aufzeichnung der Daten erfolgte durch die Software SILAB[®] des WIVW mit einer Abtastrate von 60 Hz im .csv Format.



Abbildung 3.2. Messmotorrad KTM Duke (WIVW GmbH)

Des Weiteren wurde die Fahrt mittels einer an der Fahrzeugfront befestigten 360°-Kamera des Fabrikats Insta360 X3 aufgezeichnet. Im Postprocessing konnten somit verschiedene Perspektiven gewählt werden, welche Fahrbahn, Fahrer oder Umgebung darstellen. Die Mess- und Videodaten wurden mittels eines von der Messtechnik zyklisch ausgegebenen Signaltons über den Mikrofon-Eingang der Kamera synchronisiert, sodass eine Zuordnung des jeweiligen Videoframes zur entsprechenden Zeile der Messdaten erfolgen konnte.

3.2 Experteninterviews

Da das Thema „Linienwahl von Motorradfahrern“ in der wissenschaftlichen Literatur zum Zeitpunkt der Erstellung dieser Arbeit nur wenig Beachtung fand und keine Untersuchungen zu den zugrundeliegenden Faktoren existierten, wurden ein Experteninterview zur Identifikation potentieller Faktoren durchgeführt.

Im November 2024 wurden in einem teil-strukturierten Online-Interview sechs Experten befragt, welche im Bereich Motorradfahrer-Verhalten in der Verkehrsfor-schung tätig waren und/oder über einschlägige Erfahrung auf dem Gebiet der Fahr-ausbildung von Motorradfahrern verfügen.

3 Methodik

Es wurden befragt:

1. Christoph Meyke, Fahrtrainer ADAC Hessen/Thüringen
2. Martin Winkelbauer, Verkehrsforscher Kuratorium für Verkehrssicherheit (europäischer Verkehrssicherheitspreis 2024)
3. Hannes Bagar, Fahrlehrer und Fahrsicherheitstrainer 1000ps Straßentraining
4. Klaus Schwabe, Fahrlehrer und Fahrsicherheitstrainer KTM Riders Academy
5. André Lang, Verkehrsforscher IFZ Institut für Zweiradsicherheit
6. Thomas Schmieder, Redakteur Zeitschrift MOTORRAD

In dem ca. 30 minütigen Interview wurden folgende, offene Fragen gestellt:

1. In welchem Rahmen haben Sie sich bisher mit dem Thema „Linienwahl von Motorradfahrern“ auseinandergesetzt?
2. Was charakterisiert Ihrer Meinung nach eine „sichere Linie“?
3. Welche Faktoren haben Ihrer Meinung nach einen Einfluss darauf, dass ein Motorradfahrer eine unsichere Linie nutzt?
4. Was ist Ihrer Meinung nach die Hauptursache für das Verfehlen der geplanten Linie?
5. Durch welche Maßnahmen könnte Ihrer Meinung nach die Linienwahl sicherer gestaltet werden?

Die Ergebnisse der Interviews wurden im Nachgang transkribiert und in einer thematischen Analyse aggregiert.

Auswertung Experteninterview

Was charakterisiert eine „sichere“ Linie?

Alle Experten erwähnten einstimmig, dass „*die eine* sichere Linie“ in Form einer immer gültigen Universallösung, nicht existiere. Es wurde darauf verwiesen, dass speziell in der Fahrausbildung aus didaktischen Gründen oft das „Hinterschneiden“ bzw. „Außen anfahren“ von Kurven unterrichtet würde, da es viele Vorteile biete. Jedoch hänge die ideale, sichere Linie in hohem Maße von der Situation und dem Fahrer ab, seltener wurde ebenso das Fahrzeug (Art des Motorrads) als Faktor genannt. Alle führten den Aspekt an, dass eine sichere Linie zu jeder Zeit „Reserven“ bietet soll, d.h. auf unvorhergesehene Situationen reagiert werden kann, ohne dass ein Unfall die Folge wäre. In diesem Zuge wurde oft das Thema „Sicht“ genannt.

Zusammenfassend kann bemerkt werden, dass als Hauptaspekt die Kontrollierbarkeit der Situation durch den Fahrer benannt und dabei speziell die antizipatorische, zukunftsgerichtete Komponente betont wurde. Die Linienwahl soll eine bewusste Entscheidung des Fahrers auf Basis der in der konkreten Situation vorliegenden Informationen sein und dabei die individuellen Handlungsmöglichkeiten berücksichtigen. Es kann festgehalten werden, dass eine möglichst gute Sicht in die Kurve die Information und damit die Sicherheit verbessert und dass individuelle Schräglagen-Limits eine Erhöhung der Trajektorien-Krümmung unter Umständen limitieren. Aus diesen Gründen gilt das Hinterschneiden, welches die Sicht in die Kurve erhöht und am Kurvenausgang ausreichend Reserven zum äußeren Fahrbahnrand bereitstellt, gerade in der Fahrausbildung als „Sicherheitslinie“. Ein sehr geübter Fahrer, für welchen eine hochdynamische Anpassung der Linie in Schräglage keine Herausforderung darstellt, hat jedoch grundlegend andere Voraussetzungen als ein Fahranfänger.

Welche Faktoren haben Ihrer Meinung nach einen Einfluss darauf, dass ein Motorradfahrer eine unsichere Linie nutzt?

Der am häufigsten angeführte Punkt war eine „mangelnde Auseinandersetzung“ mit dem Thema Linienwahl bzw. den Sicherheitsaspekten diesbezüglich, viele Fahrer führen einfach „irgendwie“. Dass sich daraus eine unsichere (zu enge) Linie ergebe, wurde auf eine mögliche „natürliche Tendenz zum Kurvenschneiden“ zurückgeführt.

Speziell die Fahrtrainer berichteten davon, dass das Hinterschneiden, also das verspätete Einlenken in eine Kurve, ein Verhalten wäre, das bewusst geübt werden müsse und nicht intuitiv praktiziert würde. Es würde „Überwindung kosten“. Zudem wurde mehrfach berichtet, dass Fahrer vehement bestreiten würden, eine Kurve zu eng angefahren zu sein und sehr überrascht wären, wenn sie mit der Außenansicht aus Videoaufnahmen konfrontiert werden. Über eine potenzielle Wahrnehmungsverzerrung der Lage von Fahrer und Motorrad in Schräglage wurde theoretisiert. Die Angst vor dem Fahrbahnrand bzw. der Leitplanke wurde als weiterer Grund für das zu enge Anfahren von Kurven genannt. Unter Umständen spiele auch ein allgemeines Informationsdefizit eine Rolle, da die Fahrausbildung in der Regel schon sehr weit zurück läge. Ebenso wurde häufig die Blickführung als Faktor für eine unsichere Linienwahl angeführt. Beim Fahren in Gruppen sei eine enge Linie eine gängige Kompensationsstrategie für mangelnde Fahrfähigkeiten („um mithalten zu können“), da der engere Radius weniger Kurvengeschwindigkeit und Schräglage nötig mache. Alle Experten betonten, dass die Linienwahl multifaktoriell und entsprechend sehr komplex sei.

Abschließend kann zusammengefasst werden, dass die Mehrheit zu enges Anfahren von Kurven als intuitives Verhalten benennt, welches „abtrainiert“ werden muss bzw. einen bewussten Entscheidungsprozess dagegen benötigt.

Was ist Ihrer Meinung nach die Hauptursache für das Verfehlen der geplanten Linie?

Die Mehrheit der Experten dementierte einen maßgeblichen Einfluss mangelnden Fahrkönnens aus dem eine Nutzung von unsicheren Linien resultiere. Mit wenigen Ausnahmen seien die Fahrer durchaus in der Lage eine geplante Linie in etwa zu treffen, bzw. sei dies nach Meinung der Mehrheit nicht als Hauptursache für eine schlechte Linienwahl zu sehen. Dennoch sei eine Korrektur der Linie in der Kurve aufgrund von persönlichen Schräglagenlimits für viele durchaus ein Thema, da zu wenig Reserve vorhanden sei. Ebenso seien motorische Lenkblockaden in Folge von Schrecksituationen ein häufiger Grund für das Verfehlen von geplanten Linien.

Durch welche Maßnahmen könnte Ihrer Meinung nach die Linienwahl sicherer gestaltet werden?

Am häufigsten wurde das Fahrtraining, sowie allgemein Maßnahmen zur Auseinandersetzung mit der Thematik und zur Sensibilisierung genannt. Häufig wurde auch auf bauliche Maßnahmen, wie zusätzliche Fahrbahnmarkierungen verwiesen, welche jedoch nicht flächendeckend umgesetzt werden könnten und nur punktuell an Unfall-Hotspots Abhilfe schüfen. Ein Umdenken in der Fahrausbildung in Bezug auf die „Gefahrenlehre“ wurde ebenso diskutiert.

3.3 Prädiktorenauswahl und Hypothesengenerierung

Basierend auf der thematischen Analyse in Kapitel 2 und dem Ergebnis des Experteninterviews in 3.2 wurden folgende, mit dem vorliegenden Datensatz untersuchbare, Prädiktoren definiert:

Prädiktor Fahrerfahrung

Die Daten lagen in 1000km/Lebenszeit als Schätzung - durch die Probanden selbst - vor. Die Motorrad-Fahrerfahrung wurde als wichtiger personeller Faktor gewählt.

Getrieben von der Annahme, dass geübte Fahrer „besser“ fahren, wurde folgende Hypothese formuliert:

H_11 : Fahrer mit hoher Fahrerfahrung halten mehr Abstand zur Gegenfahrbahn.

UV: Gegenverkehr

Die Daten wurden auf Basis der Videoaufnahmen gewonnen und dichotom pro Kurve codiert. 0 entspricht keinem Gegenverkehr, 1 entspricht Gegenverkehr vor oder in der Kurve.

Der Risikohomöostase-Theorie in 2.2 folgend wurde die Hypothese aufgestellt:

H_12 : Bei Gegenverkehr wird mehr Abstand zur Gegenfahrbahn eingehalten.

UV: Einsehbarkeit der Kurve

Anhand der Videodaten wurden die Kurven in drei Klassen eingeteilt. 2 entspricht „Kurve komplett einsehbar“, 1 entspricht „Kurve teilweise einsehbar“, 0 entspricht „Hohe Randbebauung, sehr schlecht einsehbar“.

Anknüpfend an die UV Gegenverkehr, wurde ebenfalls die Einsehbarkeit der Kurve als Prädiktor ausgewählt. Aufgrund des Risikos durch plötzlich auftauchenden Gegenverkehrs in uneinsehbaren Kurven, wurde angenommen, dass die Einsehbarkeit positiv mit unsicheren Linien korreliert.

H_13 : In schlecht einsehbaren Kurven wird mehr Abstand zur Gegenfahrbahn eingehalten.

UV: Kurvenradius

Der Kurvenradius auf Basis des Krümmungsverlaufs des GPS-Tracks lag im Datensatz bereits vor. Es wurde jeweils das lokale Minimum pro Kurve gewählt.

Der Kurvenradius wurde als Faktor gewählt, da die Ergebnisse in 2.1 nahelegen, dass enge Kurven häufiger geschnitten werden.

H_14 : Je kleiner der Kurvenradius, desto weniger Abstand zur Gegenfahrbahn wird eingehalten.

UV: Mittellinie

Die Kurven wurden dichotom codiert, 1 entspricht „Mittelstreifen vorhanden, 0 entspricht „kein Mittelstreifen“.

Es wurde ein negativer Zusammenhang bezüglich des Vorhandenseins einer Mittellinie angenommen, da der Mittelstreifen als Orientierung dient und die Grenze zur Gegenfahrstreifen eindeutig kenntlich macht. Des Weiteren korreliert er negativ mit der Fahrstreifenbreite, was gemäß der Ergebnisse in 2.1 den erwarteten Effekt noch verstärken sollte.

H_15 : Bei vorhandenem Mittelstreifen (breitere Straße) wird mehr Abstand zur Gegenfahrbahn eingehalten.

UV: Fahrgeschwindigkeit

Die Fahrgeschwindigkeit in km/h konnte direkt den GPS-Messwerten des Datensatzes entnommen werden.

Unter der Annahme, dass eine niedrigere Fahrgeschwindigkeit mit einem niedrigeren wahrgenommenen Risiko einher geht, wurde angenommen:

H_{16} : Kleinere Fahrgeschwindigkeit führt zu weniger Abstand zur Gegenfahrbahn.

3.4 Statistische Auswertung

Die Datenverarbeitung erfolgte weitgehend in python, wie in 4.1 näher beschrieben. Zur deskriptiven und inferenzstatistischen Analyse wurde JASP 0.18, sowie IBM SPSS in der Version 28 eingesetzt.

Ausreißer und Extremwerte wurden einer individuellen Plausibilisierung unterzogen. Konnte dies im Abgleich mit den Videodaten als Fehldetektion des Postprocessing-Algorithmus identifiziert werden, erfolgte ein Ausschluss. Es wurden keine Datenpunkte aufgrund hoher Streuung bei validen Messwerten ausgeschlossen.

Es wurde eine multiple, lineare Regression mit den in 4.1 genannten Variablen durchgeführt. Die Voraussetzungen wurden im Vorfeld geprüft, nicht erfüllte Voraussetzungen werden in 4 genannt und in 5 thematisiert.

4 Ergebnisse

4.1 Postprocessing

4.1.1 Framework

Die Verarbeitung der Daten erfolgte in Python 3.12 mithilfe der Library pandas (<https://pandas.pydata.org/>). Um häufig wiederkehrende Schritte bei der Analyse der Daten sinnvoll zu organisieren, wurde ein rudimentäres Framework erstellt. Fortfolgend eine Erläuterung der Klassen Dataloader, VideoPlayer, FrameAnnotator und TrackLoader, sowie des Maptools welches zur explorativen Arbeit mit dem Datensatz erstellt wurde.

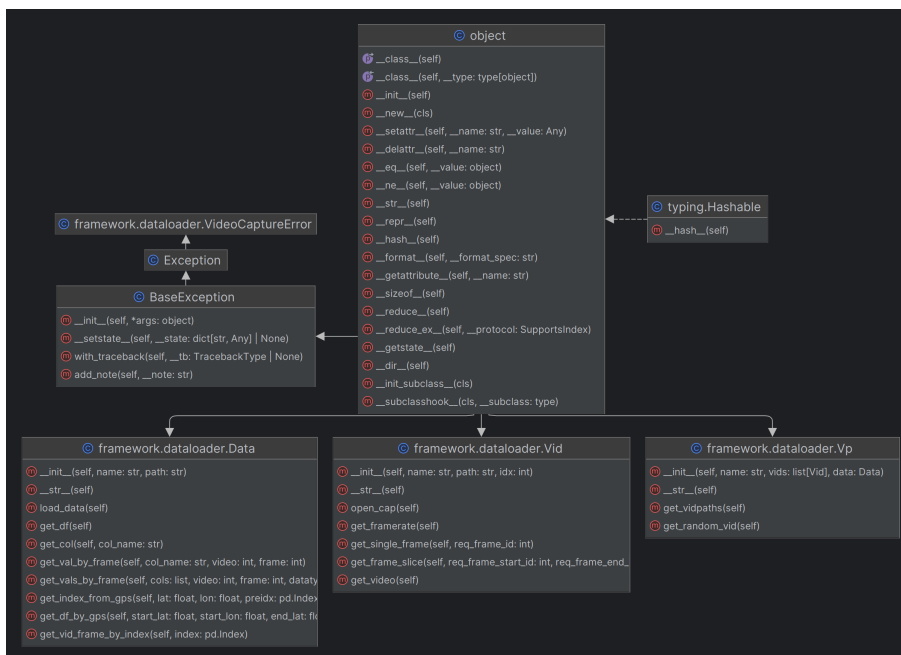


Abbildung 4.1. UML-Diagramm Dataloader

Wie in Abb. 4.1 dargestellt, deklariert der Dataloader die Klassen *Vp* (kurz für Versuchsperson), *Vid* (für Videodaten) sowie *Data* (für Messdaten). Pro Versuchsperson wird eine Instanz der Klasse *Vp* erstellt, welche wiederum eine *Data*-Instanz

pro .csv-Messdaten-Datei und eine Vid-Instanz pro Video-Datei enthält. Die Klassen verwalten die Eigenschaften der jeweiligen Daten-Objekte und implementieren Funktionen zum Laden, Filtern und Zurückgeben von Datensegmenten.

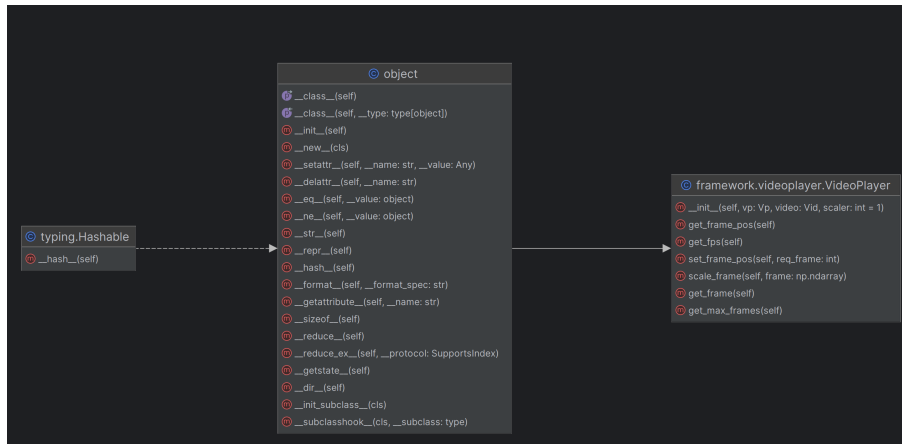


Abbildung 4.2. UML-Diagramm VideoPlayer

Die in Abb. 4.2 illustrierte Klasse `VideoPlayer` organisiert Eigenschaften und Programmcode zur Wiedergabe der Videodateien mittels `opencv` (<https://opencv.org>).

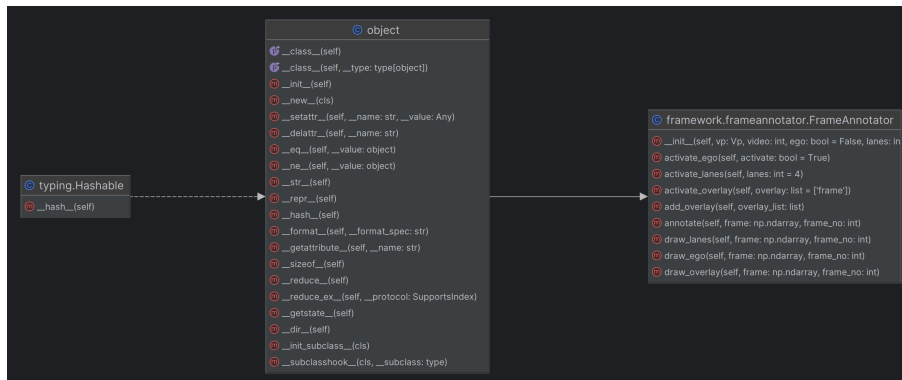


Abbildung 4.3. UML-Diagramm FrameAnnotator

Die Klasse `FrameAnnotator` (Abb. 4.3) ermöglicht die Visualisierung von Messdaten innerhalb der Videobilder. So besteht die Möglichkeit Messwerte als Text-Overlay oder die Position von Ego-Fahrzeug und/oder Fahrbahnmarkierungen als Marker zum Videobild hinzuzufügen.

Die Klasse `TrackLoader` (abgebildet in 4.4) verwaltet durch Start- und Endpunkte definierte Sektionen. Dadurch können markante Streckenabschnitte (z.B. Kurven) festgelegt und bequem organisiert werden.

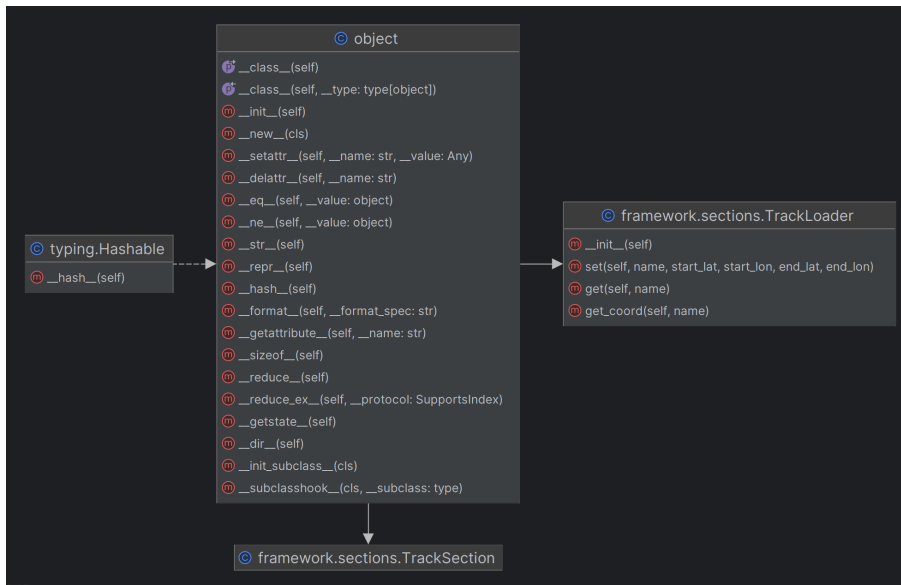


Abbildung 4.4. UML-Diagramm TrackLoader

4.1.2 Maptool

Um die explorative Arbeit mit dem sehr umfangreichen Datensatz effizienter zu gestalten, wurde ein Tool zur Visualisierung der Mess- und Videodaten entwickelt. Ziel war es, eine Möglichkeit zu schaffen, die Messdaten anhand ihrer Geo-Position anzuzeigen und unmittelbaren Zugriff auf die hinterlegten Videodaten zu haben.

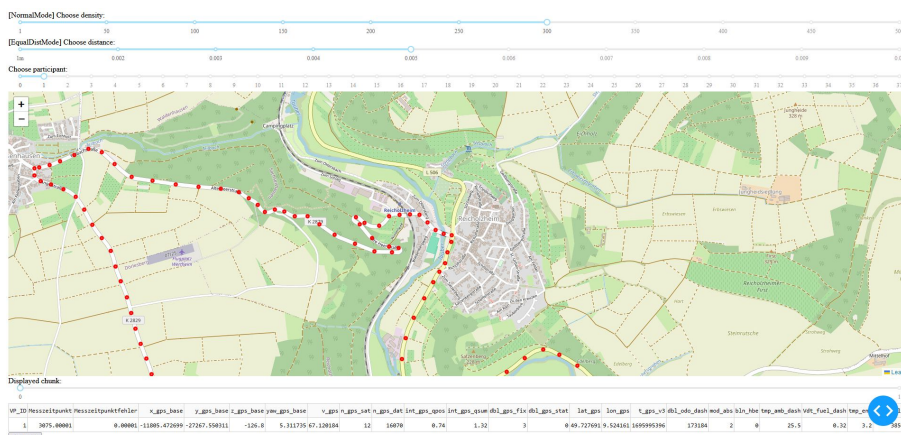


Abbildung 4.5. UI Maptool

Das in Abb. 4.5 dargestellte User-Interface (kurz UI) basiert auf der Python Library „Dash Leaflet“ (siehe <https://www.dash-leaflet.com/>) und ist über einen lokalen Webserver mittels Webbrowser aufrufbar. Kern des UI bildet eine interaktive Kartenansicht, welche einzelne Datenpunkte des ausgewählten Probanden anhand ihrer

GPS-Information darstellt. Ein Click auf einen Datenpunkt zeigt die dazugehörige Datenzeile mit allen Messwerten als Tabelle unter der Karte an. Der Button „Play Video“ öffnet ein Fenster mit dem dazugehörigen, 30-sekündigen Videostream.

Aus Performance-Gründen musste die Anzeige auf 1000 Datenpunkte gleichzeitig begrenzt werden, weshalb der komplette Datensatz in Chunks geladen wird. Da aufgrund der hochfrequenten Aufzeichnung trotzdem nur relativ kurze Streckenabschnitte angezeigt werden könnten, wird der Datensatz zusätzlich ausgedünnt. Dazu werden zwei Methoden bereitgestellt: Im „Density-Mode“ wird anhand der Benutzereingabe nur jeder x-te Wert der Messreihe geladen. Da somit die Dichte der angezeigten Daten aber in hohem Maße von der Fahrgeschwindigkeit abhängig wäre, wurde zusätzlich der „EqualDist-Mode“ implementiert, welcher Datenpunkte anhand ihrer euklidischen Distanz auswählt. Die Parameter für Density oder Distance können über das UI ausgewählt werden.

4.1.3 Videodaten

Die von der 360°-Kamera erstellten Rohdaten wurden mit der Software Insta360 Studio in einheitliche mp4-Videodateien mit einer Auflösung von 2538 x 1080 Pixeln (Verhältnis 2.35:1) und 30 Bildern pro Sekunde konvertiert. Der dabei verwendete, statische Keyframe wurde nach folgenden Kriterien gewählt:

- Azimut: Mittelebene des Motorrads bei Geradeausfahrt senkrecht.
- Elevation: Horizont bei ebener Fahrt mittig im Bild, Fender (Schutzblech) und Vorderrad sichtbar.
- Rollangle: Horizont bei Geradeausfahrt waagerecht.
- Field of view: Gesamte Straßenbreite sichtbar.
- Distortion: Rektifizierung, keine Verzerrung.

Die Optionen FlowState-Stabilization und Direction-Lock wurden aktiviert. Einen Beispiel-Frame zeigt Abb. 4.6.



Abbildung 4.6. Beispiel Videoframe

4.1.4 Ermittlung des Querversatz

Im Hinblick auf die Untersuchung der Linienwahl ist der Querversatz - als abhängige Variable (AV) - die wichtigste Größe. Der Querversatz, als relative, horizontale Position im Fahrstreifen, lässt sich somit aus der Position des Ego-Fahrzeugs und der Position der Fahrstreifenränder ermitteln. In Anbetracht einer in Deutschland üblichen Fahrstreifenbreite von 2.75 bis 3.75 m („Richtlinien für die Anlage von Landstraßen: RAL“, 2012) ermöglichen die zur Verfügung stehenden GPS-Positionsdaten (ohne stationäre Referenz) mit einer Genauigkeit von (bis zu) ± 5 m keine hinreichend genaue Bestimmung des Querversatzes. Aus diesem Grund wurde dieser aus den Video-Bilddaten ermittelt. Aufgrund der umfangreichen verfügbaren Datenmenge und ihres Potentials für aussagekräftige inferenzstatistische Analysen wurde das Ziel verfolgt, einen hohen Grad an Automatisierung im Postprocessing zu erreichen, um die Auswertung auf eine möglichst große Datenbasis stützen zu können.

Detektion und Tracking des Ego-Fahrzeugs

Im Gegensatz zu einer „herkömmlichen“, fahrzeugfest-montierten Kamera, führt das Postprocessing der 360°-Videos zu einer variablen Position des Ego-Fahrzeugs im Videoframe, da die Perspektive der Kamera am Horizont ausgerichtet wird. In Folge dessen muss für die Ermittlung des Querversatz zunächst die Position des Ego-Fahrzeugs relativ zum Bild-Koordinatensystem bestimmt werden. Um die Rechen-

zeit gering zu halten, wurde eine Kombination aus Detektion und Tracking verwendet.

Zur initialen Erkennung des Fahrzeugs im ersten Videoframe bot sich aufgrund der markanten Farbe des Fenders ein HSV-Thresholding mit folgenden Schwellwerten an:

- Hue (Farbton): 0 bis 15
- Saturation (Sättigung): 60 bis 255
- Value (Intensität): 100 bis 255

Das Bild wird dabei in opencv zunächst in den HSV-Farbraum konvertiert und im Anschluss in Abhängigkeit der Schwellwerte in ein Binärbild umgewandelt, d.h. alle Pixel welche in o.g. Farbraum liegen, werden auf 255 (weiß) gesetzt, alle die nicht darin liegen auf 0 (schwarz). Nach anschließender Kantendetektion mit dem Suzuki-Algorithmus (Suzuki & be, [1985](#)) kann die Lage und Größe der größten Kontur (in diesem Fall der Fender) ermittelt werden. Um ein zuverlässiges Tracking auch dann zu ermöglichen, wenn der Fender kurzzeitig (z.B. beim Abbiegen) aus dem Bild verschwindet, wurde die Höhe des resultierenden Rahmens (Bounding Box) um 100 Pixel vergrößert, sowie um 50 Pixel nach oben verschoben, sodass ein Teil des Reifens abgedeckt wird.

Beim Tracking konnten mit dem MOSSE-Tracking-Algorithmus (Bolme et al., [2010](#)) gute Ergebnisse erzielt werden, welcher vor allem durch seine Geschwindigkeit überzeugte und auch bei wechselnden Beleuchtungsverhältnissen ausreichend robust war. Jedoch zeigte sich nach längerer Trackingdauer ein „Wegdriften“ des erkannten Targets, was durch eine Reinitialisierung mittels HSV-Thresholding alle 2000 Frames gelöst werden konnte.

Durch eine Stapelverarbeitung konnten somit die Messdaten um die Größen `ego_x` und `ego_y` erweitert werden, welche der Position der Mitte des Fenders in x-/y-Koordinaten im Bild entsprechen.

Detektion des Fahrstreifens

Neben der Position des Ego-Fahrzeugs relativ im Bild, ist die Position der Fahrstreifenränder ausschlaggebend für die Ermittlung des Querversatz. Aufgrund der

gegebenen Ambiguität durch unterschiedlich gut sichtbare Markierungen, die teilweise auch verdeckt sein können, etc. bot sich zu diesem Zweck der Einsatz eines Neuronalen Netzes an. Als State-of-the-Art-Lösung konnten mit dem CLRNNet für Spurerkennung (Cross Layer Refinement Network for lane detection nach Zheng et al., 2022) gute Ergebnisse erzielt werden.

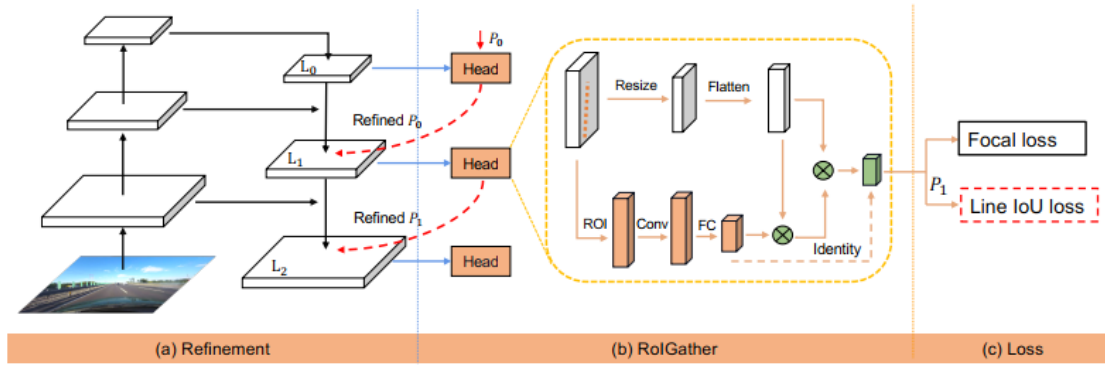


Abbildung 4.7. Aufbau CLRNnet
Zheng et al., 2022, S. 3

Das Netz basiert auf einem FPN (Feature Pyramid Network), welches faltungsbaasierte Neuronale Netze nutzt um aus den vorliegenden Bilddaten Merkmale mit unterschiedlichem Abstraktionsgrad zu generieren. So werden Spuren zunächst grob mit hochsemantischen Merkmalen erkannt, gefolgt von Verfeinerungen mit detailreichen niedrigstufigen Merkmalen, wodurch eine höhere Genauigkeit erreicht wird. Das Modul ROIGather integriert globale Kontextinformationen, um auch schwer erkennbare Spuren in herausfordernden Szenarien besser zu identifizieren. Eine für diesen Zweck maßgeschneiderte Verlustfunktion „Line IoU Loss“ behandelt Fahrspuren als zusammenhängende Einheiten, was im Gegensatz zu klassischen Punkt-zu-Punkt-Distanzen die Konsistenz und Präzision der Erkennung deutlich verbessert.

Ein Fine-Tuning des vom Autor auf Basis des CULane-Datensatzes (Pan et al., 2017) bereitgestellten, vortrainierten Modells mit 1 433 annotierten Bildern aus dem KIMoVe-Datensatz, lieferte mit einem F1-Score von 73% auf den Test-Datensatz im 80/10/10-Split ein zufriedenstellendes Ergebnis. Alle Parameter des Modells finden sich in 5. Die Vorhersage (prediction) des Modells umfasst bis zu vier erkannte Fahrstreifenmarkierungen bzw. -begrenzungen, jeweils repräsentiert durch eine Punktschar (x-/y-Koordinaten) im Bild-Koordinatensystem (vgl. Abb. 4.8). Aufgrund der anzunehmenden, endlichen Änderungsrate der Fahrstreifen-Positionen im Bild und der benötigten Rechenzeit für die Vorhersage, wurde nur jeder zehnte Videoframe

(entsprechend 3 Bildern pro Sekunde) verarbeitet.



Abbildung 4.8. Beispiel CLRnet prediction mit rechtem Fahrbahnrand (gelb), linkem (grün) und Mittelstreifen (magenta)

Datenverarbeitung

Um die Qualität der so gewonnen Daten zu verbessern und eine möglichst hohe Verfügbarkeit des Querversatzes zu gewährleisten, wurden die Daten entsprechend nachbearbeitet: Die bei der Integration, der mit $f = 30$ Hz (Bildwiederholrate der Videos) vorliegenden Ego-Positionsdaten in den Hauptdatensatz mit $f = 60$ Hz, entstandenen Fehlstellen wurden linear interpoliert.

Die Integration der Daten der Fahrstreifenbegrenzungen in den Hauptdatensatz stellte aus Gründen der Datenqualität eine Herausforderung dar. Zum Einen lagen die Daten nur mit $1/10$ der Frequenz des Hauptdatensatzes vor, was eine Interpolation nötig machte, zum Anderen enthielten sie False-Negatives und False-Positives. Da das Modell keine konsekutive, sondern eine unabhängige Vorhersage lieferte, war zunächst eine Gruppierung der Daten nötig. Das Modell lieferte für jeden Videoframe Informationen zu den erkannten Fahrstreifenbegrenzungen, von denen jedoch nur maximal vier erkannt wurden und die lageabhängig von rechts nach links aufsteigend nummeriert wurden. Wurde in einem Frame neben der - zuvor korrekt erkannten - rechten Fahrstreifenbegrenzung lm_0 , noch eine weitere, weiter rechts verortete Begrenzung erkannt, wurden alle anderen Begrenzungen mit lm_{x+1} zurückgegeben, was ein einfaches Glätten und Interpolieren der Daten unmöglich machte.

Eine Reduktion der Daten auf die relevanten Merkmale, durch die Berechnung des Schnittpunkts der erkannten Fahrbahnbegrenzungen mit einer horizontalen Geraden durch die ego_y-Koordinate, vereinfachte die Visualisierung und Transformation der Daten.

Um Ausreißer und Fehlstellen zu korrigieren war also zunächst eine Clusterbildung nötig, welche die Datenpunkte einer real vorhandenen Fahrbahnbegrenzung zuordnete. Bedingt durch die komplexe Struktur der Fahrstreifenbegrenzungen über den kompletten Datensatz, war dieses Vorgehen nur auf kleine Streckenabschnitte anwendbar, in welchen die zu erwartende Anzahl der Fahrstreifenbegrenzungen konstant war.

An dieser Stelle musste leider von dem anfänglichen Ziel, den kompletten Datensatz in vollem Umfang auswerten zu können, abgewichen werden.

Kurvenselektion

Aufgrund der Befunde in 2.1 wurden fünf Linkskurven mit unterschiedlichen Parametern selektiert:

Tabelle 4.1. Tabelle Kurvenparameter

| Kurve | Parameter | | | | |
|---------|-----------|------------|-------------------------|----------------|---------------|
| | ID | Radius [m] | Umschlingungswinkel [°] | Mittelstreifen | Einschbarkeit |
| Heerstr | 0 | 60 | 120 | 1: Ja | 1: gut |
| K2880 | 1 | 40 | 150 | 0: Nein | 2: sehr gut |
| L506 | 2 | 140 | 125 | 1: Ja | 2: sehr gut |
| L509_L1 | 3 | 50 | 115 | 0: Nein | 0: schlecht |
| L509_L2 | 4 | 35 | 90 | 0: Nein | 0: schlecht |

Hinweis: Die Einschbarkeit wurde subjektiv bewertet, siehe 3.3



Abbildung 4.9. Kartendarstellung der selektierten Kurven mit Umschlingungswinkeln (rot)

Eine Liste der GPS-Koordinaten zu den in Abb. 4.9 dargestellten Kurven, findet sich in 5.

Die Datenpunkte wurden auf Kurveneingang, Scheitelpunkt und Kurvenausgang reduziert, definiert durch (vgl. Abb. 4.10):

- Scheitelpunkt: lokales Maximum/Minimum des geglätteten Rollwinkels
- Kurveneingang: erster Nulldurchgang des Rollwinkels *vor* Scheitelpunkt
- Kurvenausgang: erster Nulldurchgang des Rollwinkels *nach* Scheitelpunkt




Abbildung 4.10. Definition Kurvenabschnitte

Aufgrund des durch Kurvenfahrten gekrümmten Verlaufs der Werte, konnten die Daten nicht durchgängig linear separiert werden. Dichtebasierte Clusterverfahren lieferten aufgrund der Fehlstellen keine zufriedenstellenden Ergebnisse. Die besten Ergebnisse erzielte der in der Library scikit (<https://scikit-learn.org/>) integrierte EM-Algorithmus mit Gaußschen Mischmodellen (expectation-maximization with gaussian-mixture models), welcher jedoch im Falle von stark gekrümmten Verläufen zu invaliden Vorhersagen tendierte.

Dies konnte durch vorherige Transformation und spätere Rücktransformation der Daten mit dem gewichteten, geglätteten Messwerts des Rollwinkels ϕ_{imu} verbessert werden, welche die Signalverläufe fürs Clustering begründet, da die Translation der Fahrstreifenbegrenzung im Bild in hohem Maße von der Schräglage des Motorrads bei Kurvenfahrt abhängig ist. Die gruppierten Daten wurden dann linear interpoliert (auf 3 Hz) um Fehlstellen zu füllen, um im Anschluss mit der in

pandas integrierten rolling-Window-Median-Operation (Breite = 3, center = True, min_periods = 1) Ausreißer zu korrigieren.

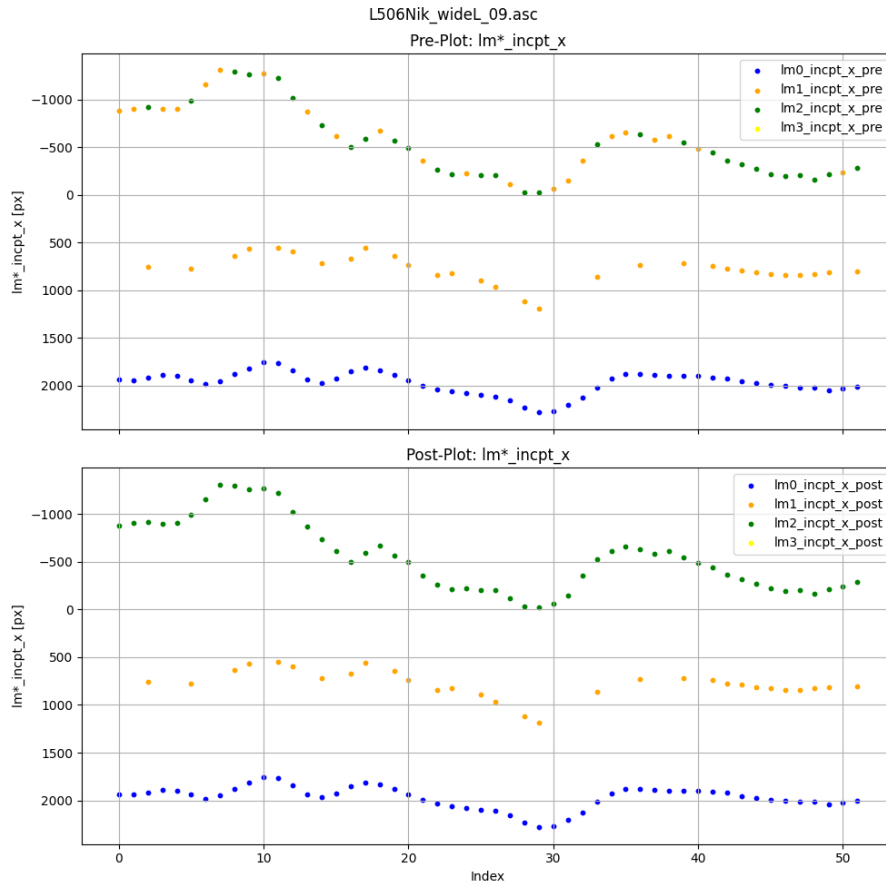


Abbildung 4.11. Datenclustering vorher/nachher

Abbildung 4.11 zeigt ein Beispielbild vor und nach den o.g. Bearbeitungsschritten.

AV1: Querversatz

Aus den, dem Ego-Punkt nächstgelegenen Schnittpunkten auf Höhe der Horizontalen, wurde der Abstand zur rechten Fahrbahnmarkierung *distRight* und die Fahrstreifenbreite *laneWidth* ermittelt (vgl. Abb. 4.12). Der Querversatz *egoLanePos* ergibt sich damit aus:

$$egoLanePos = \frac{distRight}{laneWidth}$$



Abbildung 4.12. Berechnung Querversatz: Fahrbahnmarkierungen (gelb), Ego-Punkt (türkis), Fahrstreifenbreite (grün), Abstand zum rechten Fahrbahnrand (blau)

Im Falle eines nicht vorhandenen Mittelstreifens, erfolgt die Berechnung mit $\text{laneWidth}/2$. Nähert sich der Fahrer dem rechten Fahrbahnrand, wird der Wert kleiner, nähert er sich dem Mittelstreifen, wird der Wert größer. Ein Fahren auf der Gegenfahrbahn geht mit Werten >100 einher.

AV2: Kritischer Querversatz

Zur Abgrenzung sicherheitskritischer Werte des Querversatzes in Linkskurven, wurde als zweite AV der kritische Querversatz egoLanePosCrit definiert. Aufgrund des schräglagenbedingten Überhangs - bezogen auf den Ego-Punkt - wurde ein Schwellwert von 80% festgelegt.

Der Versuch einer Approximation des Überhangs, anhand des in den Messdaten vorhandenen Rollwinkels, normiert an der Reifenbreite im Bild, scheiterte aufgrund eines sehr hohen relativen Fehlers. Der festgelegte Wert von $>80\%$ stellt einen guten Kompromiss unter Berücksichtigung großer Fahrer und hoher Schräglagen dar.

Der kritische Querversatz egoLanePosCrit errechnet sich wie folgt:

$$\text{egoLanePosCrit} = \begin{cases} \frac{\text{distRight}}{\text{laneWidth}} - 0.8, & \text{if } \frac{\text{distRight}}{\text{laneWidth}} > 0.8 \\ 0, & \text{else} \end{cases}$$

4.2 Deskriptive Datenanalyse

Tabelle 4.2. Deskriptive Statistiken AV

| | Querversatz | |
|------|-------------|----------------|
| | egoLanePos | egoLanePosCrit |
| N | 387 | 387 |
| M | 56.63 | 2.53 |
| SD | 22.85 | 7.65 |
| Min. | 16.79 | 0.00 |
| Max. | 142.21 | 61.21 |

Betrachtet man den gesamten Datensatz, ist der Querversatz annähernd normalverteilt (siehe Abb. 4.13 links). Wie in Tabelle 4.2 ersichtlich, liegt der Mittelwert $M = 56.63$ % leicht links der Fahrstreifenmitte und weist eine Streuung von $SD = 22.85$ auf. Es fällt auf, dass die äußersten 16.79% des Fahrstreifens (rechter Rand) nie und die äußersten 30% nur selten genutzt werden. Der Maximalwert der Beobachtungen liegt mit 142.21% annähernd in der Mitte des Gegen-Fahrstreifens.




Abbildung 4.13. Histogramm Querversatz (links) und Boxplot Querversatz nach Kurvenabschnitt (rechts)

Gefiltert nach dem Kurvenabschnitt zeigt sich der niedrigste Mittelwert, sowie die geringste Streuung an Kurveneingängen (siehe Abb. 4.13 rechts).

4 Ergebnisse




Abbildung 4.14. Boxplot Querversatz nach Kurvenradius und Umschlingungswinkel

In Bezug auf die Kurvenparameter Radius und Umschlingungswinkel (dargestellt in Abb. 4.14) zeigen sich keine systematisch erkennbaren Effekte.




Abbildung 4.15. Boxplot Fahrgeschwindigkeit über Kurvenabschnitt

Über alle Beobachtungen hinweg zeigte sich die niedrigste, durchschnittliche Fahrgeschwindigkeit am Scheitelpunkt der Kurve, sowie die höchste am Kurvenausgang (vgl. Abb. 4.15).




Abbildung 4.16. Scatterplot Querversatz am Scheitelpunkt über Fahrgeschwindigkeit (links) und Rollwinkel (rechts)

Die Regressionsgerade des Querversatzes (gefiltert nach Scheitelpunkt) in Abbildung 4.16 (links) offenbart einen negativen Zusammenhang zwischen Querversatz und Fahrgeschwindigkeit, d.h. mit höherer Geschwindigkeit wurde weiter außen gefahren. Gleiches gilt für den Rollwinkel (rechts).




Abbildung 4.17. Boxplot Querversatz nach Versuchsperson

Individuelle Tendenzen sind sowohl in Lage, als auch Streuung des Querversatzes erkennbar.

Wohingegen einzelne Fahrer sehr konstante Linien fahren (vgl. Fahrer 16 oder 32 Abb. 4.17), weisen andere hohe Streuungen auf (vgl. 8 und 28). Ebenso ist festzuhalten, dass der Mittelwert einiger Fahrer bereits im linken Drittel des Fahrstreifens verortet ist.

4 Ergebnisse

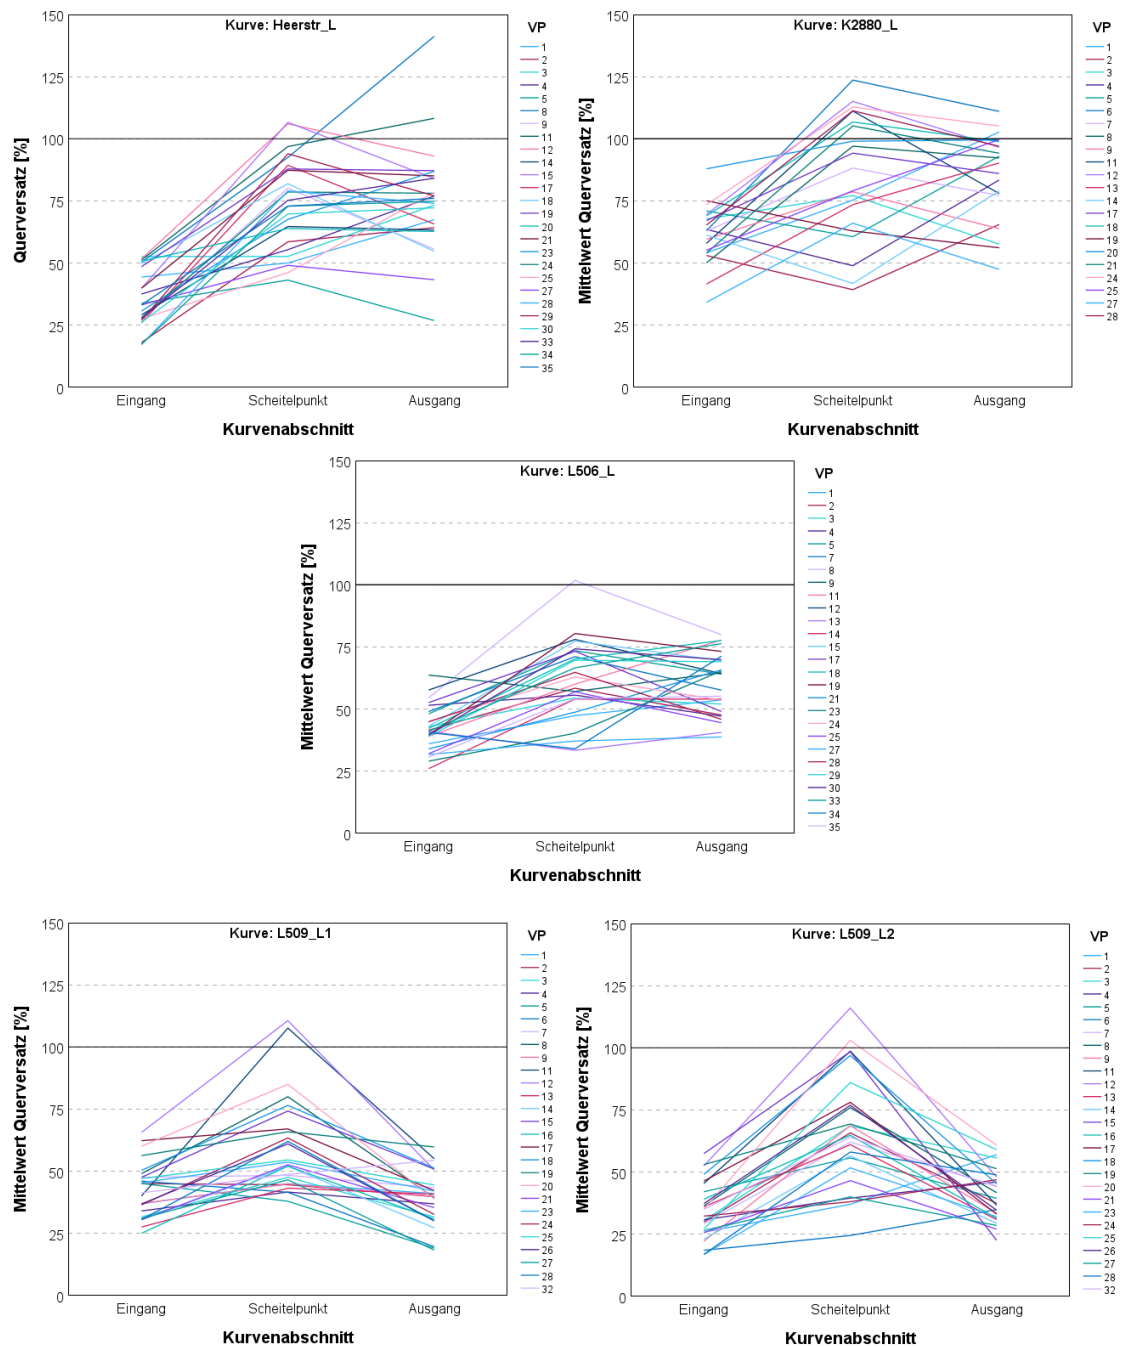


Abbildung 4.18. Individueller Querversatz nach Kurve

Trägt man den individuellen Querversatz einzeln über die Kurvenabschnitte ab (Abb. 4.18), zeigen sich in jeder Kurve einzigartige Muster. Auffällig ist die, im Gegensatz zum recht homogenen Kurveneingang, zunehmende Streuung der Messwerte am Scheitelpunkt der Kurven. Ebenso sind sehr unterschiedliche Steigungen der Graphen zu verzeichnen, welche meist im Scheitelpunkt ihr Maximum bzw. Mini-

mum aufweisen. Bezogen auf die Lage kann festgehalten werden, dass die Nutzung der Gegenfahrbahn ($>100\%$ Querversatz) mit wenigen Ausnahmen hauptsächlich am Scheitelpunkt der Kurve erfolgt.




Abbildung 4.19. Verteilung der Gradient-Kategorien

Kategorisiert nach dem Vorzeichen des Gradienten zwischen Kurveneingang und Scheitelpunkt, sowie Scheitelpunkt und Kurvenausgang, zeigt sich eine klare Dominanz der Kategorie „plusminus“ (Querversatz steigt zum Scheitelpunkt und nimmt danach ab) mit einem Anteil von 68.20 % (siehe Abb. 4.19). Kumuliert haben die zum Scheitelpunkt steigenden Kategorien einen Anteil von 90.70 %.




Abbildung 4.20. Gradient-Kategorien nach Versuchspersonen

In der individuellen Darstellung der Gradient-Kategorien zeigen sich teilweise sehr stabile Muster (vgl. VP 12 und 28 Abb. 4.20). Des Weiteren ist festzuhalten, dass die seltenen, zum Scheitelpunkt hin fallenden Beobachtungen (minus...) über unterschiedliche Probanden verteilt sind und somit keine individuellen Tendenzen darstellen.

Kritischer Querversatz




Abbildung 4.21. Histogramm krit.Querversatz (links) und Anzahl krit.Querversatz nach Kurvenabschnitt

Erwartungsgemäß weist der kritische Querversatz - bedingt durch den asymmetrischen Schwellwert - eine stark linkssteile Verteilung mit einem Mittelwert von $M = 2.526$ und einer Streuung von $SD = 7.651$ auf (vgl. Abb. 4.21, sowie Tabelle 4.2). Das

Balkendiagramm (Abb. 4.21 rechts) zeigt den kritischen Querversatz als dichotome Variable, gruppiert nach dem Kurvenabschnitt. Fallen am Kurveneingang nur 0.8 % der Beobachtungen unter die Kategorie „Querversatz kritisch“ (unsichere Linie), sind es am Kurvenausgang 17.1 % und am Scheitelpunkt sogar 24.8 %.

4.3 Inferenzstatistische Datenanalyse

Bezogen auf die inferenzstatistische Auswertung muss bemerkt werden, dass in Betracht der zugrundeliegenden Daten von 37 Probanden aus fünf Kurven, ein systematischer Zusammenhang der Residuen angenommen werden muss. Trotz allem bewegte sich die Autokorrelation gemäß Durbin-Watson Test unter Signifikanzniveau, weshalb die Verletzung dieser Voraussetzung in Kauf genommen wurde. Der harte Cut-Off der UV *krit. Querversatz*, welcher mit einer linkssteilen Verteilung (siehe 4.21) einher geht, wirkt sich ebenso auf die Normalverteilung der Residuen bei der Modellierung aus. Unter Berücksichtigung des zentralen Grenzwertsatzes, wird dies jedoch aufgrund der ausreichend großen Stichprobe toleriert.

Eine multiple lineare Regression wurde durchgeführt, um den Einfluss von sechs Prädiktoren auf die abhängige Variable *Querversatz* zu untersuchen. Das Modell war insgesamt signifikant, $F(6, 380) = 24.25$, $p < .001$, und erklärte 27.7% der Varianz in *Querversatz* ($R^2 = .28$).

Tabelle 4.3. Ergebnisse der multiplen linearen Regression AV: Querversatz

| Prädiktor | B | β | 95% KI |
|---------------------|-----------------------|---------|---|
| Einsehbarkeit | 15.42 | .60 | [12.60, 18.25] |
| Kurvenradius | -0.14 | -.24 | [-0.24, -0.04] |
| Mittellinie | -0.71 | - | [-6.97, 5.56] |
| Fahrerfahrung | 8.50×10^{-6} | .05 | $[-7.43 \times 10^{-6}, 2.44 \times 10^{-5}]$ |
| Fahrgeschwindigkeit | -0.35 | -.26 | [-0.50, -0.19] |
| Gegenverkehr | -6.97 | - | [-12.35, -1.59] |

Die Analyse zeigte, dass *Einsehbarkeit* ($p < .001$), *Kurvenradius* ($p = .006$), *Fahrgeschwindigkeit* ($p < .001$) und *Gegenverkehr* ($p = .011$) signifikante Prädiktoren für *Querversatz* waren. Die übrigen Prädiktoren waren nicht signifikant ($p > .05$).

Unter Inkaufnahme nicht normalverteilter Residuen, wurde zusätzlich eine Modellierung des kritischen Querversatz *krit. Querversatz* mittels einer multiplen, linearen Regression anhand der o.g. sechs Prädiktoren unternommen. Das Modell war signifikant, $F(6, 380) = 10.28$, $p < .001$, und erklärte 14% der Varianz in *krit. Querversatz* ($R^2 = .14$).

Die Analyse zeigte, dass *Einsehbarkeit* ($p < .001$) und *Kurvenradius* ($p = .002$) signifikante Prädiktoren für *krit. Querversatz* waren. Die übrigen Prädiktoren waren

Tabelle 4.4. Ergebnisse der multiplen linearen Regression AV: krit.Querversatz

| Prädiktor | B | β | 95% KI |
|---------------------|-----------------------|---------|---|
| Einschbarkeit | 3.45 | .40 | [2.41, 4.48] |
| Kurvenradius | -0.06 | -.30 | [-0.10, -0.02] |
| Mittellinie | -0.68 | - | [-2.97, 1.61] |
| Fahrerfahrung | 3.94×10^{-6} | .06 | $[-1.88 \times 10^{-6}, 9.76 \times 10^{-6}]$ |
| Fahrgeschwindigkeit | -0.05 | -.12 | [-0.11, 0.00] |
| Gegenverkehr | -1.80 | - | [-3.77, 0.16] |

nicht signifikant ($p > .05$).

Die Hypothesen H_{13} und H_{14} können somit angenommen werden, wohingegen die Hypothesen H_{11} und H_{12} , sowie H_{15} und H_{16} verworfen werden.

5 Diskussion

Methodisch muss bemerkt werden, dass die Entscheidung für die Aufzeichnung der Videodaten mittels 360°-Kamera, zwar durchaus entscheidende Vorteile z.B. bei der Rekonstruktion einzelner Fahrmanöver bietet, aber aufgrund der umfangreichen und nicht weiter nachvollziehbaren Postprocessing-Schritte der Kamerahersteller-Software eine automatisierte Auswertung der Daten deutlich erschwert. Die automatische Horizontierung führt zu einer Relativbewegung des Ego-Fahrzeugs im Videobild, welche einen zusätzlichen Schritt in der Daten-Nachbearbeitung nötig macht (Tracking des Ego-Fahrzeugs). Die Kamera-Rohdaten werden mittels zwei gegenüberliegenden, leicht überlappenden Fischaugen-Objektiven aufgezeichnet, um die 360° Darstellung zu ermöglichen. Die damit einhergehende Verzerrung kann durch Nachbearbeitung in Insta360-Studio (Dewarp) zwar weitgehend entfernt werden, jedoch weisen die Bilder gerade im Randbereich noch deutlich erkennbare Deformationen auf. Es ist davon auszugehen, dass sich dies negativ auf die Validität der, durch Bilddaten gewonnenen Messgrößen auswirkt. Dies sollte in zukünftigen Untersuchungen berücksichtigt werden. Allerdings ist zu beachten, dass das gewählte Verfahren keinen Anspruch auf hochpräzise Messungen erhebt und die entstehende Unschärfe zur Beantwortung der Fragestellung nicht von Relevanz ist. Der dabei entstehende Fehler kann als gleichverteilt angenommen werden, sodass er sich in der relativen Betrachtung ohnehin weitgehend ausgleicht.

Der Grundgedanke einer Naturalistic Riding Study, nämlich die möglichst unauffällige Datengewinnung über einen langen Zeitraum hinweg, um „natürliches Verhalten“ beobachten zu können, kann im gegebenen Fall sicherlich zur Diskussion gestellt werden. Auch wenn mit einer Fahrstrecke von über 120 km und über 2h Fahrzeit ein relativ großer Zeitraum betrachtet wurde, muss davon ausgegangen werden, dass alleine das zur Verfügung gestellte, „fremde“ Messmotorrad einen Einfluss auf das Verhalten der Probanden hatte. Speziell Unterschiede im Handling zum eigenen Motorrad, könnten sich in erheblichem Maße als Störgröße mit auf die Linienwahl ausgewirkt haben. Aufgrund der schwierigen Quantifizierbarkeit dieser Unterschiede

ist eine Kontrolle nur schwer bzw. nicht umsetzbar. Beschränkt man die Datenaufzeichnung auf Video- und GPS-Daten, wäre ggf. für die Zukunft eine Messfahrt mit dem eigenen Motorrad eine Option, da die Messtechnik ohne nennenswerte Eingriffe am Fahrzeug integriert werden kann.

Wie in 4.1.4 erwähnt, stellte das Clustering der Fahrbahnmarkierungen aufgrund der komplexen Datenstruktur eine große Herausforderung dar und es musste vom anfänglichen Vorhaben - den ganzen Datensatz in der Untersuchung zu berücksichtigen - abgewichen werden. Die Reduktion des Datensatzes auf fünf selektierte Kurven, reduzierte die Stichprobengröße drastisch und schränkt die Modellgüte möglicherweise ein. Ebenso waren aufgrund von Streckensperrungen und Ausfällen der Messtechnik nicht von jedem Probanden alle Datenpunkte verfügbar, was dies noch verstärkte. Die Generalisierbarkeit der Ergebnisse würde von einer Vergrößerung der Stichprobe profitieren. Die Modellbildung könnte dann durch eine Aufteilung in Trainings-, Validierungs- und Testdaten weiter verbessert werden.

Des Weiteren entstehen Limitationen durch die Verwendung des bestehenden Datensatzes, welcher nicht konkret auf die vorliegende Fragestellung ausgerichtet wurde und gerade in Bezug auf die, dem beobachteten Verhalten zugrundeliegenden Motive, einige Fragen offenlässt. Wie in 3.2 mehrfach benannt, zeichnet eine „sichere Linie“ aus, dass der Fahrer diese bewusst in Anbetracht der vorliegenden Situation gewählt hat. Informationen diesbezüglich müssten unmittelbar bzw. idealerweise direkt nach der jeweiligen Kurve abgefragt werden und konnten im vorliegenden Fall nach ca. einem Jahr nicht nacherhoben werden. Beobachten wir einen Fahrer, welcher eine Kurve unmittelbar auf dem Mittelstreifen anfährt, bleibt dies unter der Voraussetzung, dass er uneingeschränkte Einsicht in die Kurve hatte und die Situation gut einschätzen konnte, ein sicheres und valides Verhalten. War der Fahrer hingegen unkonzentriert und lies sich mehr oder weniger gedankenlos zur Fahrbahnmittle treiben, jedoch nicht. Es wurde versucht diesem Umstand durch die Auswahl von nicht- bzw. schlecht einsehbaren Kurven zu entgegnen.

Inhaltlich kann festgehalten werden, dass die zu beobachtenden Unterschiede in der Linienwahl höchstwahrscheinlich multifaktoriell bedingt sind und nicht allein auf personelle bzw. umweltbedingte Faktoren zurückzuführen sind. Es zeigen sich interessante Zusammenhänge zwischen den berücksichtigten Prädiktoren und dem beobachteten Verhalten der Probanden. Ein positiver, signifikanter Zusammenhang

zwischen der Einsehbarkeit der Kurve und dem Querversatz erscheint augenscheinlich valide und lässt sich gut im Rahmen der Risikohomöostase-Theorie erklären. Ist die Kurve einsehbar, d.h. das Risiko eher kalkulierbar, wird tendenziell enger angefahren d.h. unter Umständen der Gegenfahstreifen mitbenutzt. Gleiches gilt für den negativen Zusammenhang mit dem Vorhandensein von Gegenverkehr. Die Beobachtung, dass mit zunehmender Fahrgeschwindigkeit mehr Abstand zur Gegenfahrbahn eingehalten wurde, entspricht ebenfalls der Annahme der RHT einer Risikokompensation durch größeren Abstand zur Gegenfahrbahn. Der positive Zusammenhang zwischen Kurvenradius und Querversatz entspricht der Erwartung in Bezug auf die Ergebnisse zur energieökonomischen Tendenz in 2.1.

Betrachtet man die Ergebnisse der inferenzstatistischen Analyse bezogen auf den kritischen Querversatz, offenbart sich ein signifikanter, positiver Zusammenhang mit der Einsehbarkeit und ein negativer Zusammenhang mit dem Kurvenradius, was die Hypothesen H_{13} und H_{14} bestätigt. Verblüffend hingegen ist das Ergebnis, dass die Fahrerfahrung über keinerlei Vorhersagekraft für die Linienwahl verfügt, d.h. erfahrene Fahrer ihre Linie weder „besser“ noch „schlechter“ wählen, als Fahranfänger. Dies überrascht besonders unter Berücksichtigung dessen, dass eine schlechte Liniwahl die Fahrsicherheit erheblich einschränkt und somit zu gefährlichen Situationen führen könnte, welche lerntheoretisch als negative Konsequenz wahrgenommen und damit das Auftreten des Verhaltens reduzieren sollte. Möglicherweise führt eine Wahrnehmungsverzerrung der eigenen Fahrstreifenposition in Schräglage (vgl. Experteninterview 3.2) zu einer externen Attribution, was eine Verhaltensanpassung verhindert.

Trotz der genannten methodischen Herausforderungen zeigt die vorliegende Arbeit, dass durch die Anwendung einer innovativen Methodik in einem weitgehend unbeforschten Bereich bedeutsame Erkenntnisse gewonnen werden können. Die Kombination aus videobasierter Fahrstilanalyse und inferenzstatistischen Modellen liefert robuste Ergebnisse zur Linienwahl von Motorradfahrern und offenbart bisher nicht dokumentierte Zusammenhänge zwischen Sichtverhältnissen, Fahrgeschwindigkeit und seitlicher Positionierung. Damit leistet die Studie einen wertvollen Beitrag zur Verkehrssicherheitsforschung und schafft eine Grundlage für weiterführende Untersuchungen sowie mögliche praxisrelevante Anwendungen, beispielsweise in der Fahrassistenz oder der Gestaltung von Kurvenführungen im Straßenverkehr.

Literatur

- ADAC e.V. (2023). Analyse von schweren Verkehrsunfällen mit Motorradbeteiligung. *ADAC Unfallforschung* (siehe S. 2).
- Angermann, R., & Schwabe, K. (2018). Different approaches with regard to safe cornering lines and how to adopt them – background information and possible improvements. *IFZ Tagungsband*, (12), 391–424 (siehe S. 3).
- Bärgman, J. (2016). *Methods for Analysis of Naturalistic Driving Data in Driver Behavior Research*. [Disseration]. Chalmers University of Technology. Department of Applied Mechanics. (Siehe S. 6).
- Bella, F. (2005). Speeds and Lateral Placements on Two-Lane Rural Roads: Analysis at the Driving Simulator (siehe S. 4).
- Bolme, D., Beveridge, J. R., Draper, B. A., & Lui, Y. M. (2010). Visual object tracking using adaptive correlation filters. *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2544–2550 (siehe S. 24).
- Bundesanstalt für Straßenwesen. (2021). Zum Unfallgeschehen von Motorrädern. *Mensch und Sicherheit*, (M 304) (siehe S. 2).
- Center for Urban Transportation Research CUTR. (2018). Study on Motorcycle Safety in Negotiation with Horizontal Curves in Florida and Development of Crash Modification Factors (siehe S. 2).
- Das, V. R., Jayashree, M., & Rahul, S. (2016). Lateral Placement of Vehicles on Horizontal Curves. *Transportation Research Procedia*, 17, 43–51 (siehe S. 4).
- Eccarius, T., & Lu, C.-C. (2020). Powered two-wheelers for sustainable mobility: A review of consumer adoption of electric motorcycles. *International Journal of Sustainable Transportation*, 14(3), 215–231 (siehe S. 1).
- Hicheur, H., Pham, Q.-C., Arechavaleta, G., Laumond, J.-P., & Berthoz, A. (2007). The formation of trajectories during goal-oriented locomotion in humans. I. A stereotyped behaviour. *The European journal of neuroscience*, 26(8), 2376–2390 (siehe S. 3).

- Ibrahim, M. K. A., Hamid, H., Law, T. H., & Wong, S. V. (2018). Evaluating the effect of lane width and roadside configurations on speed, lateral position and likelihood of comfortable overtaking in exclusive motorcycle lane. *Accident; analysis and prevention*, 111, 63–70 (siehe S. 4).
- Jacob, B., & Violette, E. (2012). Vehicle Trajectory Analysis: An Advanced Tool for Road Safety. *Procedia - Social and Behavioral Sciences*, 48, 1805–1814 (siehe S. 4).
- Klauer, S., Perez, M., & McClafferty, J. (2011). Naturalistic Driving Studies and Data Coding and Analysis Techniques. In B. E. Porter (Hrsg.), *Handbook of Traffic Psychology* (S. 73–85). Elsevier Science & Technology. (Siehe S. 7).
- Lemonakis, P. (2021). Investigation of Motorcycle Trajectories in 2-lane Horizontal Curves. *WSEAS TRANSACTIONS ON SYSTEMS AND CONTROL*, 16, 610–625 (siehe S. 2 f.).
- Michon, J. A. (1985). A Critical View of Driver Behavior Models: What Do We Know, What Should We Do? In L. Evans & R. C. Schwing (Hrsg.), *Human Behavior and Traffic Safety* (S. 485–524). Springer US. (Siehe S. 4).
- Özkan, T., Lajunen, T., Doğruyol, B., Yıldırım, Z., & Çoymak, A. (2012). Motorcycle accidents, rider behaviour, and psychological models. *Accident; analysis and prevention*, 49, 124–132 (siehe S. 2).
- Pan, X., Shi, J., Luo, P., Wang, X., & Tang, X. (2017). Spatial As Deep: Spatial CNN for Traffic Scene Understanding. (Siehe S. 25).
- Pettrisch, A., & Kemper, D. (2024). Influencing the trajectory of motorcyclists through strategic curve markings (siehe S. 2 f.).
- Richtlinien für die Anlage von Landstraßen: RAL (Ausg. 2012). (2012). (Siehe S. 23).
- Spacek, P. (2005). Track Behavior in Curve Areas: Attempt at Typology. *Journal of Transportation Engineering*, 131(9), 669–676 (siehe S. 4).
- Statistisches Bundesamt. (2021). Verkehrsunfälle: Kraftrad- und Fahrradunfälle im Straßenverkehr 2021 (siehe S. 1).
- Statistisches Bundesamt. (2023). Verkehrsunfälle 2023: Statistischer Bericht (siehe S. 1).
- Suzuki, S., & be, K. (1985). Topological structural analysis of digitized binary images by border following. *Computer Vision, Graphics, and Image Processing*, 30(1), 32–46 (siehe S. 24).
- Todorov, E. (2004). Optimality principles in sensorimotor control. *Nature neuroscience*, 7(9), 907–915 (siehe S. 4).

- Trimpop, R. M. (1996). Risk homeostasis theory: Problems of the past and promises for the future. *Safety Science*, 22(1-3), 119–130 (siehe S. 6).
- Vaa, T. (2007). The Risk Homeostasis Theory: Reject, accept or modify? - An Opposition to Gerald Wilde's RHT (siehe S. 5).
- Vasic, A.-M., & Weilenmann, M. (2006). Comparison of real-world emissions from two-wheelers and passenger cars. *Environmental science & technology*, 40(1), 149–154 (siehe S. 1).
- Wilde, G. J. (1998). Risk homeostasis theory: an overview. *Injury prevention : journal of the International Society for Child and Adolescent Injury Prevention*, 4(2), 89–91 (siehe S. 4 f.).
- Wilde, G. J. S. (1982). The Theory of Risk Homeostasis: Implications for Safety and Health. *Risk Analysis*, 2(4), 209–225 (siehe S. 5 f.).
- Winkelbauer, M. (2022). Kurvenschneiden bei Motorradfahrern: Wirksame Gegenmaßnahmen. *Zeitschrift für Verkehrsrecht ZVR*, (10), 351–360 (siehe S. 4).
- Winkelbauer, M., & Bagar, H. (2013). Kurvenlinien von Motorradfahrern in unübersichtlichen Linkskurven | 1 | Kurvenlinien von Motorradfahrern in unübersichtlichen Linkskurven Kuratorium für Verkehrssicherheit. (Siehe S. 2, 4).
- Winkelbauer, M., Krack, P., & Lamp, D. (2019). Lean Angles and Lane Positions of Motorcyclists. *Austrian Road Safety Board, Vienna* (siehe S. 3).
- Winkelbauer, M., Soteropoulos, A., Schneider, F., & Tomasch, E. (2017). Unfallursachen bei Motorradunfällen. *KFV-Sicher Leben #4* (siehe S. 2).
- Winkelbauer, M., Strnad, B., Schmied, S., & Schneider, F. (2018). Different Designs of Floor Markings: A Successful Low Cost Measure Against Motorcycle Crashes in Rural Left Hand Curves: Proceedings of 7th Transport Research Arena TRA 2018, April 16-19, 2018, Vienna, Austria (siehe S. 2 f.).
- World Health Organization. (2022). *Powered Two-And Three-wheeler Safety: A Road Safety Manual for Decision-Makers and Practitioners* (2nd ed.). (Siehe S. 1).
- Wyss, M., Schuler, D., & Ghielmetti, M. (2009). Motorradfahrer auf Bergstraßen: Unfallgeschehen und Sicherheitsmaßnahmen. *strasse und verkehr Nr. 1-2*, (1-2) (siehe S. 2).
- Xu, J., Luo, X., & Shao, Y.-M. (2018). Vehicle trajectory at curved sections of two-lane mountain roads: a field study under natural driving conditions. *European Transport Research Review*, 10(1) (siehe S. 4).

- Yu, Z., Chen, Y., Zhang, X., & Xu, J. (2021). Track Behavior and Crash Risk Analysis of Passenger Cars on Hairpin Curves of Two-Lane Mountain Roads. *Journal of Advanced Transportation*, 2021, 1–15 (siehe S. 4).
- Zheng, T., Huang, Y., Liu, Y., Tang, W., Yang, Z., Cai, D., & He, X. (2022). CLRNet: Cross Layer Refinement Network for Lane Detection. (Siehe S. 25).

Anhang A. CLRnet Parameter

```
1 net = dict(type='Detector', )
2
3 backbone = dict(
4     type='DLAWrapper',
5     dla='dla34',
6     pretrained=True,
7 )
8
9 num_points = 72
10 max_lanes = 4
11 sample_y = range(589, 230, -20)
12
13 heads = dict(type='CLRHead',
14              num_priors=192,
15              refine_layers=3,
16              fc_hidden_dim=64,
17              sample_points=36)
18
19 iou_loss_weight = 2.
20 cls_loss_weight = 2.
21 xyt_loss_weight = 0.2
22 seg_loss_weight = 1.0
23
24 work_dirs = "work_dirs/clr/dla34_KIMOVE"
25
26 neck = dict(type='FPN',
27             in_channels=[128, 256, 512],
28             out_channels=64,
29             num_outs=3,
30             attention=False)
31
```

```

32 test_parameters = dict(conf_threshold=0.4, nms_thres=50,
    nms_topk=max_lanes)
33
34 epochs = 15
35 batch_size = 24
36
37 optimizer = dict(type='AdamW', lr=0.6e-3) # 3e-4 for
    batchsize 8
38 total_iter = (2224 // batch_size) * epochs
39 scheduler = dict(type='CosineAnnealingLR', T_max=total_iter)
40
41 eval_ep = 3
42 save_ep = 10
43
44 img_norm = dict(mean=[103.939, 116.779, 123.68], std=[1.,
    1., 1.])
45 ori_img_w = 1640
46 ori_img_h = 590
47 img_w = 800
48 img_h = 320
49 cut_height = 270
50
51 train_process = [
52     dict(
53         type='GenerateLaneLine',
54         transforms=[
55             dict(name='Resize',
56                 parameters=dict(size=dict(height=img_h,
57                     width=img_w)),
58                 p=1.0),
59             dict(name='HorizontalFlip',
60                 parameters=dict(p=1.0), p=0.5),
61             dict(name='ChannelShuffle',
62                 parameters=dict(p=1.0), p=0.1),
63             dict(name='MultiplyAndAddToBrightness',
64                 parameters=dict(mul=(0.85, 1.15), add=(-10,
65                     10)),
66                 p=0.6),

```

```

63         dict(name='AddToHueAndSaturation',
64               parameters=dict(value=(-10, 10)),
65               p=0.7),
66         dict(name='OneOf',
67               transforms=[
68                   dict(name='MotionBlur',
69                         parameters=dict(k=(3, 5))),
69                   dict(name='MedianBlur',
70                         parameters=dict(k=(3, 5)))
71               ],
72               p=0.2),
73         dict(name='Affine',
74               parameters=dict(translate_percent=
75                               y=(-0.1, 0.1)),
76                               rotate=(-10, 10),
77                               scale=(0.8, 1.2)),
78               p=0.7),
79         dict(name='Resize',
80               parameters=dict(size=dict(height=img_h,
81                                         width=img_w)),
82               p=1.0),
83     ],
84     dict(type='ToTensor', keys=['img', 'lane_line', 'seg']),
85 ]

```

Listing A.1. Konfiguration für CLRnet

Anhang B. GPS-Koordinaten Kurven

Tabelle B.1. Tabelle Kurvenparameter

| Kurve | GPS-Koordinaten | | | |
|---------|-----------------|-----------------|---------------|----------------|
| | Start Latitude | Start Longitude | Ende Latitude | Ende Longitude |
| Heerstr | 49.728094 | 9.51747 | 49.728431 | 9.516019 |
| K2880 | 49.669417 | 9.625011 | 49.668264 | 9.625455 |
| L506 | 49.682141 | 9.630807 | 49.683816 | 9.627833 |
| L509_L1 | 49.695103 | 9.545420 | 49.696054 | 9.546396 |
| L509_L2 | 49.699538 | 9.543682 | 49.700072 | 9.544583 |

Anhang C. Datenpunkt-Ausschlüsse

Tabelle C.1. Tabelle Ausschlüsse

| VP | Ausschluss | |
|----|------------|---|
| | Kurve(n) | Begründung |
| 6 | 0 und 2 | Messdaten-/Video-Synchronisierung fehlerhaft. |
| 10 | alle | Keine Daten ab Niklashausen. Ausfall Messtechnik |
| 13 | 0 | Markierungsdetektion invalide. |
| 15 | 1 | Markierungsdetektion invalide. |
| 16 | 0 bis 2 | Routenabweichung |
| 20 | 2 | GPS-Match fehlerhaft. |
| 22 | alle | Keine Videodaten. |
| 23 | 1 | Markierungsdetektion invalide. |
| 26 | 0 bis 2 | Ego- und Markierungsdetektion invalide (starker Regen). |
| 29 | ab 2 | Streckensperrung, Alternativroute. |
| 30 | ab 2 | Streckensperrung, Alternativroute. |
| 31 | alle | Keine Messdaten. |
| 32 | ab 2 | Streckensperrung, Alternativroute. |
| 33 | ab 2 | Streckensperrung, Alternativroute. |
| 34 | ab 2 | Streckensperrung, Alternativroute. |
| 35 | ab 2 | Streckensperrung, Alternativroute. |
| 36 | alle | Routenabweichung. |
| 37 | alle | Routenabweichung + Dunkelheit. |

Selbstständigkeitserklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit selbständig und ohne Benutzung anderer als der angegebenen Quellen und Hilfsmittel angefertigt habe.

Alle Stellen, die wörtlich oder sinngemäß aus veröffentlichten oder nicht veröffentlichten Schriften entnommen wurden, sind als solche kenntlich gemacht.

Die Arbeit hat in gleicher oder ähnlicher Form noch keiner anderen Prüfungsbehörde vorgelegen.

Würzburg, 24. Februar 2025

Oliver Krauß

Titel der

Thema bereitgestellt von (Titel, Vorname, Nachname, Lehrstuhl):

Eingereicht durch (Vorname, Nachname, Matrikel):

Ich versichere, dass ich die vorstehende schriftliche Arbeit selbständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe. Die benutzte Literatur sowie sonstige Hilfsquellen sind vollständig angegeben. Wörtlich oder dem Sinne nach dem Schrifttum oder dem Internet entnommene Stellen sind unter Angabe der Quelle kenntlich gemacht.

Weitere Personen waren an der geistigen Leistung der vorliegenden Arbeit nicht beteiligt. Insbesondere habe ich nicht die Hilfe eines Ghostwriters oder einer Ghostwriting-Agentur in Anspruch genommen. Dritte haben von mir weder unmittelbar noch mittelbar Geld oder geldwerte Leistungen für Arbeiten erhalten, die im Zusammenhang mit dem Inhalt der vorgelegten Arbeit stehen.

Mit dem Prüfungsleiter bzw. der Prüfungsleiterin wurde abgestimmt, dass für die Erstellung der vorgelegten schriftlichen Arbeit Chatbots (insbesondere ChatGPT) bzw. allgemein solche Programme, die anstelle meiner Person die Aufgabenstellung der Prüfung bzw. Teile derselben bearbeiten könnten, entsprechend den Vorgaben der Prüfungsleiterin bzw. des Prüfungsleiters eingesetzt wurden. Die mittels Chatbots erstellten Passagen sind als solche gekennzeichnet.

Der Durchführung einer elektronischen Plagiatsprüfung stimme ich hiermit zu. Die eingereichte elektronische Fassung der Arbeit ist vollständig. Mir ist bewusst, dass nachträgliche Ergänzungen ausgeschlossen sind.

Die Arbeit wurde bisher keiner anderen Prüfungsbehörde vorgelegt und auch nicht veröffentlicht. Ich bin mir bewusst, dass eine unwahre Erklärung zur Versicherung der selbstständigen Leistungserbringung rechtliche Folgen haben kann.

Ort, Datum, Unterschrift