



Fakultät II - Informatik, Wirtschafts- und Rechtswissenschaften
Department für Informatik

*Menschmodellierung für adaptive
Straßenfahrzeuge*

Von der Fakultät für Informatik, Wirtschafts- und
Rechtswissenschaften der Carl von Ossietzky Universität
Oldenburg zur Erlangung des Grades und Titels eines

Doktors der Naturwissenschaften

angenommene Dissertation

von Alexander Trende

geboren am 13.04.1990 in München

Gutachter: Prof. Dr. Martin Fränze
Prof. Dr. Jochem W. Rieger

Datum der Einreichung: 19.01.2023
Datum der Verteidigung: 13.07.2023

Eigenständigkeitserklärung

Ich versichere, dass ich die vorliegende Arbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt und die allgemeinen Prinzipien wissenschaftlicher Arbeit und Veröffentlichungen, wie sie in den Leitlinien guter wissenschaftlicher Praxis der Carl von Ossietzky Universität Oldenburg festgelegt sind, befolgt habe.

Zusammenfassung

Der Fortschritt in der Entwicklung von Cyber-Physical Systems (CPS) hat zu einer immer stärkeren Integration der Systeme und des Menschen geführt. Diese sogenannten Human-Cyber-Physical Systems (HCPS) und die damit einhergehende engere Kooperation zwischen Menschen und CPS soll sicherheitskritische Situationen reduzieren und CPS effizienter gestalten. Es ist jedoch äußerst wichtig, dass der Mensch in diesen Systemen die zentrale Rolle spielt. Ein gemeinsamer Nenner von Referenzarchitekturen für solche HCPS ist eine Komponente, welche das menschliche Verhalten und Zustände bei der Nutzung von HCPS modellieren kann. Diese Menschmodelle ermöglichen es dem HCPS dynamisch auf eben jene Zustände und Verhalten einzugehen. So können sicherheitskritische Situationen, welche durch negativen Menschzustände oder Verhalten verursacht werden im Vorhinein verhindert beziehungsweise der Schaden minimiert werden.

Hochautonome Fahrzeuge (HAV) eignen sich insbesondere durch den hohen Automationsgrad und potentiell sicherheitskritischen Situationen des Straßenverkehrs als ausgezeichneter Use-Case für HCPS. Im Zuge dieser Arbeit wurden verschiedene Modellierungsansätze für Intentions- und Zustandserkennung für die Verwendung von HAV präsentiert. Hierbei wurde insbesondere ein Fokus auf die Synthese verschiedener Datenquellen und ein etwaige Verbesserung der Modellleistung gelegt. Solche Modelle könnten Komponenten von fortgeschrittenen Fahrassistenzsystemen sein, welche die Intention der Nutzer:innen antizipiert und bei sicherheitskritischen Situationen interveniert. Mögliche Interventionen wären eine Warnung der Nutzer:in durch Mensch-Maschine Schnittstellen oder das Eingreifen in die Fahrdynamik.

Im Kontext von hochautonomen Fahrzeugen (HAV) als HCPS wurden außerdem zwei weitere wichtige Aspekte untersucht: die Interaktion zwischen HAV und menschlichen Fahrer:innen und die Personalisierung von HAV. Beide Aspekte sind wichtig für die Nutzerakzeptanz der Technologie und somit auch die Einführung von HAV in die Gesellschaft.

Insgesamt unterstreichen die Ergebnisse dieser Arbeit, dass der Mensch in HCPS ein wichtiger, wenn nicht sogar der wichtigste Aspekt beim Design und der Entwicklung solcher Systeme sein sollte. Nur so lassen sich HCPS entwerfen, welche eine produktive und risikoarme Kooperation ermöglichen.

Abstract

The progress in the development of Cyber-Physical Systems (CPS) has led to a tighter integration of the systems and humans. These so-called human-cyber-physical systems (HCPS) and the associated closer cooperation between humans and CPS is intended to reduce safety-critical situations and make CPS more efficient. However, it is extremely important that the human plays the central role in these systems.

A common denominator of reference architectures for such HCPS is a component that can model human behavior and states when using HCPS. These human models enable the HCPS to respond dynamically to those conditions and behaviors. In this way, safety-critical situations that are caused by negative human states or behavior can be prevented in advance or the damage could be minimized.

Highly autonomous vehicles (HAV) are particularly suitable as an use-case for HCPS due to the high degree of automation and potential safety-critical traffic situations. In the course of this work, different modeling approaches for intention and state recognition for the use of HAV were presented. A particular focus was placed on the synthesis of different data sources and a possible improvement of the model performance. Such models could be components of advanced driver assistance systems that anticipate user intentions and intervene in safety-critical situations. Possible interventions would be to warn the user through human-machine interfaces or to alter the driving dynamics.

In the context of highly autonomous vehicles (HAV) as HCPS, two other important aspects were also investigated: the interaction between HAV and human drivers and the personalization of HAV. Both aspects are important for the user acceptance of the technology and thus the introduction of HAV into society.

Overall, the results of this work underline that the human in HCPS should be an important, if not the most important, aspect in the design and development of such systems. This is the only way to design HCPS that enable productive and low-risk cooperation.

Danksagung

Mit großer Dankbarkeit und Freude möchte ich an dieser Stelle all denen meinen aufrichtigen Dank aussprechen, die mich auf meinem Weg zur Vollendung meiner Doktorarbeit begleitet und unterstützt haben. Ohne euch wäre dieses bedeutende Kapitel in meinem Leben nicht möglich gewesen.

Zunächst möchte ich mich bei meinem Doktorvater Martin Fränzle bedanken, der mir die einmalige Möglichkeit gab, an diesem interessanten Projekt zu arbeiten. Seine fachliche Kompetenz, motivierende Unterstützung und Empathie waren von unschätzbarem Wert und haben mich stets dazu ermutigt diese Arbeit fertigzustellen.

Ein besonderer Dank gilt auch meinem Zweitbetreuer Jochem Rieger, der sich stets die Zeit genommen hat, meine Forschungsarbeiten und Publikationen der letzten Jahre zu lesen, zu unterstützen und mit wertvollen Anmerkungen und Rückmeldungen zu verbessern.

Großer Dank geht auch an Andreas Lüdtkke, welcher mich in den letzten fünf Jahren immer unterstützt und gefördert hat.

Ich danke allen weiteren Mitarbeiter:innen der 'Human-Centered Design' Gruppe des OFFIS, die mich immer wieder ermutigt haben und mit denen ich viele inspirierende Diskussionen führen durfte. Ihre moralische Unterstützung und Motivation waren ein wichtiger Antrieb für mich, den Forschungsweg fortzusetzen.

Zuletzt gebührt meiner Familie und Freunden mein herzlichster Dank für ihre bedingungslose Liebe und unermüdliche Unterstützung während all der Jahre. Ihr Glaube an mich und mein Potenzial hat mir die Kraft gegeben, auch in schwierigen Zeiten durchzuhalten.

C: *Wow, it really snowed last night! Isn't it wonderful?*

H: *Everything familiar has disappeared! The world looks brand-new!*

C: *A new year... a fresh, clean start!*

H: *It's like having a big white sheet of paper to draw on!*

C: *A day full of possibilities!*

It's a magical world Hobbes, ol' buddy...

...Let's go exploring!

Bill Watterson

Inhaltsverzeichnis

1	Einleitung	3
1.1	Motivation	3
1.2	Forschungsfragen & Wissenschaftlicher Beitrag	8
1.3	Forschungsmethoden	12
1.4	Aufbau der Arbeit	12
1.5	Publikationen	15
2	Grundlagen	19
2.1	Zustands- und Intentionserkennung beim Autofahren	19
2.2	Psychophysiologische Messverfahren	21
2.3	Neuroimaging	23
2.4	Fahrsimulatorstudien	26
2.5	Maschinelles Lernen	30
3	Klassifikation von Abbiegeintention	45
3.1	Einführung	45
3.2	Material & Methoden	48
3.3	Klassifikation von Abbiegeintention mit Bayesschen Netzen	51
3.4	Integriertes Modell zur Klassifikation der Abbiegeintention	55
3.5	Diskussion	63
3.6	Fazit	69

4	Interaktion mit autonomen Fahrzeugen	71
4.1	Einführung	71
4.2	Material & Methoden	73
4.3	Studie 1: Unterschiede beim Abbiegeverhalten im hybriden Verkehr .	76
4.4	Modellierung des Abbiegeverhaltens im hybriden Verkehr	78
4.5	Studie 2: Unterschiede in der gewählten Lückengröße beim Abbiege- verhalten im hybriden Verkehr	81
4.6	Diskussion	84
4.7	Fazit	87
5	Unsicherheitserkennung im autonomen Fahren	89
5.1	Einführung	89
5.2	Material & Methoden	91
5.3	Ergebnisse	95
5.4	Diskussion	97
5.5	Fazit	98
6	Fahrstilpersonalisierung von autonomen Fahrzeugen	101
6.1	Einleitung	101
6.2	Material und Methoden	103
6.3	Ergebnisse	109
6.4	Diskussion	116
6.5	Fazit	118
7	Fazit, Limitierungen & Ausblick	119
7.1	Fazit	119
7.2	Limitierungen	123
7.3	Ausblick	124
	Referenzen	127

Abbildungsverzeichnis	143
Tabellenverzeichnis	149
Appendix	151
Fahrstil Fragebogen	151
Technologieakzeptanz Fragebogen	154

Kapitel 1

Einleitung

1.1 Motivation

Der Fortschritt in der Entwicklung von Cyber-Physical Systems (CPS) in den letzten Jahren hat zu einer immer stärkeren Integration der Systeme und des Menschen geführt. Diese sogenannten Human-Cyber-Physical Systems (HCPS) und die damit einhergehende engere Kooperation zwischen Menschen und CPS soll sicherheitskritische Situationen reduzieren und CPS effizienter gestalten [Sztipanovits et al., 2019]. Beispiele für solche HCPS sind automatisiertes und vernetztes Fahren, Smart Cities oder intelligente Energiesysteme (s. Abb. 1.1). Damit HCPS effizient und sicher genutzt werden können müssen diese Systeme adaptiv und reaktiv sein [Sztipanovits et al., 2019].

Für die Integration des Menschen in ein HCPS wurden bereits von vielen Forscher:innen Referenzarchitekturen vorgestellt [Sowe et al., 2019, Sun et al., 2020a, Zhou et al., 2019]. Die meisten dieser Referenzarchitekturen haben gemein, dass sie eine oder mehrere Komponenten haben, welche den Zustand und das Verhalten des Menschen mithilfe von (neuro- und psychophysiologischer) Sensorik erkennen können (s. Abbildung 1.2). Entsprechend des erkannten Menschzustands kann die Planung beziehungsweise Handlungen der CPS Komponente des HCPS angepasst werden. Mithilfe der kontinuierlichen Messung des Menschzustands und der darauf basieren-



Abbildung 1.1: Beispiele für Human-Cyber-Physical Systems. **Links oben:** Autonomes Fahrzeug von Waymo. **Rechts oben:** Roboter-assistierte Operation. **Links unten:** Industrieroboter von KUKA. **Rechts unten:** Intelligente und vernetzte Städte und Energiesysteme.

den Erkennung eben jenes Zustandes entsteht so eine Feedbackschleife, welche die notwendige Reaktivität und Adaptivität des HCPS ermöglicht. Die Bestimmung des Menschzustands während der Nutzung kann Aufschlüsse auf notwendige Verbesserungen am CPS oder der Schnittstelle zwischen Mensch und CPS geben. Relevante Zustände sind hierbei unter Anderem kognitive Arbeitslast oder Unsicherheit über die (sichere) Funktionalität des CPS. Ist der Mensch etwa einer zu hohen kognitiven Arbeitslast ausgesetzt kann das HCPS Hilfsmaßnahmen ergreifen, um diese Arbeitslast zu verringern oder den Menschen mithilfe von Mensch-Computer Schnittstellen vor Überlastung zu warnen. Dies ist insbesondere bei der Steuerung eines Fahrzeuges relevant. Hierbei kann die Fahrer:in gewarnt werden, damit entweder ein anderer Mensch oder die Fahrzeugautomation die Kontrolle über das Fahrzeug übernimmt. So kann sicherheitskritischen Situationen vorgebeugt werden.

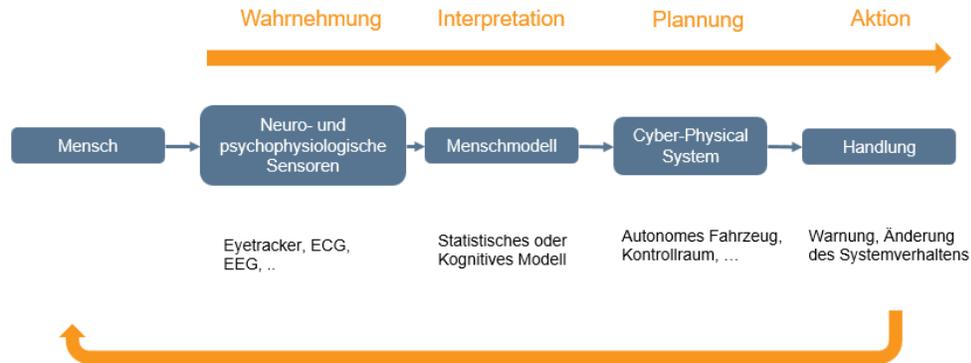


Abbildung 1.2: Die Referenzarchitektur stellt die vier integralen Handlungsschritte bzw. Komponenten eines Human-Cyber-Physical Systems dar: Wahrnehmung, Interpretation, Planung, Aktion [Vorgestellt von Prof. Dr. Martin Fränzle]

Eines der prominentesten Beispiele für HCPS sind hochautomatisierte Fahrzeuge (*HAV, highly automated vehicles*). Die Einführung von HAV wird einen weitreichenden Einfluss auf unsere Gesellschaft haben, denn in Deutschland gab es im Jahre 2022 48.5 Millionen Autos und in ganz Europa etwa 250 Millionen. Die Forschung und Entwicklung von autonomen Fahren verspricht die Reduktion von menschlichen Fehlern und somit eine Verringerung von Verkehrsunfällen. Die Vernetzung von HAV mithilfe von *Vehicle-to-everything* Technologie kann potentiell den Verkehr effizienter gestalten, indem die Kontrolle der Fahrzeuge zentral gesteuert wird [Harding et al., 2014]. Außerdem sollen HAV die Nutzung von Fahrzeugen im Allgemeinen komfortabler machen, indem die Nutzer:innen sich während der Fahrt anderen Aktivitäten widmen können.

Für die längste Zeit seit der Erfindung von Automobilen wurden diese vollständig von Menschen gesteuert. In der zweiten Hälfte des 20. Jahrhunderts wurde mit dem Antiblockiersystem (ABS) das erste Fahrassistenzsystem in kommerziell verfügbare Fahrzeuge integriert [Galvani, 2019]. Dies war ein erster Schritt mithilfe von neuen technischen Systemen die Fahrzeugführung für den Menschen sicherer und

komfortabler zu machen. Insbesondere in den letzten Jahrzehnten wurden weitere Systeme entwickelt. Hierbei werden Aufgaben der Fahrzeugführung automatisiert und Kontrolle über das Fahrzeug vom Menschen zum Assistenzsystem übergeben. Beim Tempomat übergibt beispielsweise der Mensch die Regelung der Fahrzeuggeschwindigkeit. Die Übergabe von Kontrolle erfordert ein hohes Maß an Vertrauen und Sicherheit über die sichere Funktionalität der Automation. Insbesondere da Autofahren eine sehr komplexe und potentiell sicherheitskritische Tätigkeit ist. Damit eine sichere Übergabe der Kontrolle über das Fahrzeug beziehungsweise bestimmte Fahraufgaben durchgeführt werden kann müssen sowohl Mensch als auch Fahrzeug auf diese Übergabe vorbereitet sein. Eine Methode, um diese Bereitschaft zur Übergabe sicherzustellen ist die Erkennung und Überwachung des Menschzustands [Morales-Alvarez et al., 2020].

Solche Intentions- oder Zustandserkennungsmodelle können genutzt werden, um eine Vielzahl an unterschiedlichen Fahrassistenzsystemen zu entwickeln. Ein solches System kann risikoreiche Intentionen des Menschen erkennen und entsprechend durch das Eingreifen in die Fahrdynamik oder Warnung des Menschen intervenieren. Für solche Zustands- und Intentionserkennungen ist es von Vorteil, dass hochautonome Fahrzeuge bereits sehr umfangreiche Sensorik für die Erkennung des Verkehrskontexts besitzen. In der Vergangenheit wurden bereits vielfach die Zustands- und Intentionserkennung beim Führen eines Fahrzeugs untersucht [Unni et al., 2015, Berndt et al., 2008, Beggiano et al., 2018]. Bisher wurden hierfür meist entweder nur neurobeziehungsweise psychophysiologischen Messverfahren oder Kontext- beziehungsweise Fahrdynamikparameter verwendet. Eines der Ziele der in dieser Arbeit beschriebenen Forschungsarbeiten ist zu zeigen, dass die Integration von Messdaten aus unterschiedlichen Datenquellen nützlich für solche Erkennungsmodelle ist und sich somit deren Leistung verbessern lässt.

Wie bereits oben beschrieben kann ein hypothetisches Fahrassistenzsystem bei der Erkennung eines suboptimalen Menschzustands eingreifen und zum Beispiel eine Warnung an den Menschen weitergeben. Eine weitere Möglichkeit wäre die Änderung der Fahrdynamik, um auf den Menschzustand zu reagieren. Wurde zum Beispiel erkannt, dass die Fahrt für den Menschen nicht komfortabel ist kann ein anderer Fahrstil vom HAV gewählt und angewendet werden. Abbildung 1.3 zeigt die In-

stanzierung der in 1.2 dargestellten Architektur für ein solches adaptives System zur Erkennung von Ermüdung beim manuellen Autofahren. Ein Eye Tracker misst den Pupillendurchmesser der Fahrer:in. Ein Ermüdungserkennungsmodell verwendet diese Messdaten, um eine potenzielle Ermüdung der Fahrer:in festzustellen. Falls Ermüdung festgestellt wurde, kann das Fahrzeug eine graphische oder auditorische Nutzerschnittstelle aktivieren, um die Fahrer:in auf die Ermüdung aufmerksam zu machen. Eine weitere Möglichkeit wäre das Einleiten eines Bremsmanövers.

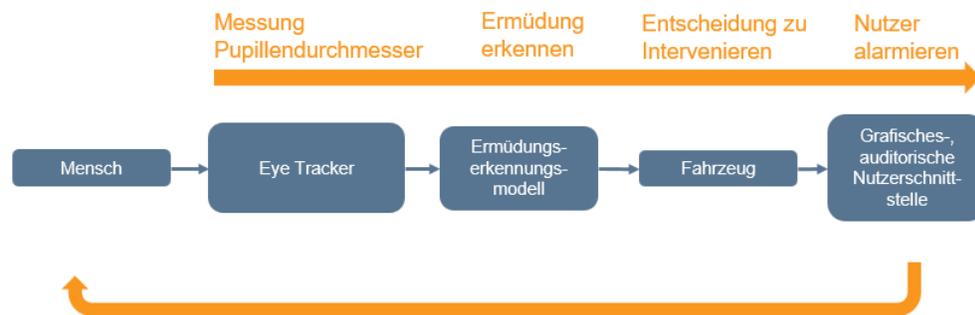


Abbildung 1.3: Instanziierung der HCPS Architektur aus 1.2. Hierbei wurde das Beispiel eines Systems zur Erkennung von Müdigkeit während des Steuern eines Fahrzeuges gewählt.

Wie bereits oben beschrieben existiert in HCPS eine Feedbackschleife, welche auf die Nutzer:in reagieren kann. Die Änderung der Fahrdynamik ist ein Beispiel hierfür. Jedoch können sich Fahrstilpräferenzen sehr stark zwischen einzelnen Menschen unterscheiden [Basu et al., 2017, Hartwich et al., 2018, Trende et al., 2019a]. Die Untersuchung von Fahrstilpräferenzen für verschiedene Fahrer:innen ist ein wichtiges Forschungsthema, da es maßgeblich die Akzeptanz und somit Adoption von autonomen Fahrzeugen beeinflusst. So kann die Adoption der Technologie behindert werden, wenn ein HAV einen Fahrstil verwendet, welcher nicht komfortabel für eine Nutzer:in ist. Es kann also sinnvoll sein, dass Nutzer:innen den Fahrstil des HAV an ihre Präferenzen anpassen. Hierzu wurde im Zuge dieser Arbeit ebenfalls eine Fahrsimulatorstudie durchgeführt.

Ein weiterer wichtiger Aspekt, welcher die Akzeptanz und somit die Einführung von HAV in den Straßenverkehr beeinflusst, ist die Interaktion zwischen Menschen und HAV. In der Übergangsphase von manuell gesteuerten Fahrzeugen zu ausschließlich HAVs wird es auf den Straßen einen hybriden Verkehr geben. Besonders in dieser Phase ist es wichtig, nicht nur die Interaktion des Menschen als Nutzer des HAV zu betrachten, sondern auch die Interaktion zwischen Menschen welche als Außenstehende mit HAV interagieren. Hierbei ist es wichtig zu verstehen, welches mentale Modell Menschen von HAV besitzen und ob dieses möglicherweise zu sicherheitskritischen Situationen führen kann. In dieser Arbeit werden die Forschungsergebnisse aus zwei Fahrsimulatorstudien hinsichtlich der Untersuchung zu Mensch-HAV und Mensch-Mensch Interaktionen im Straßenverkehr präsentiert.

1.2 Forschungsfragen & Wissenschaftlicher Beitrag

Im Zuge dieser Arbeit im Rahmen von unterschiedlichen Forschungsprojekten, wie zum Beispiel dem DFG Projekt *PIRE: Science of Design for Societal-Scale Cyber-Physical Systems* oder dem BMWI Projekt *AutoAkzept*, an mehreren wichtigen Einzelkomponenten von Fahrassistenzsysteme gearbeitet. Ein Fokus lag hierbei insbesondere an den sogenannten Menschmodellen, welche Nutzerzustände oder Verhalten erkennen können. Die folgenden Abschnitte stellen hierzu die entsprechenden Forschungsfragen und wichtigsten Ergebnisse dieser Forschungsarbeiten dar.

1.2.1 Integriertes Modell zur Intentionserkennung

Abbiegen durch den entgegenkommenden Verkehr kann zu sicherheitskritischen Situationen führen [Hamed et al., 1997, Harding et al., 2014] und trägt zu 7.4% aller leichten Unfällen bei [Harding et al., 2014]. Menschliche Fehler, insbesondere das falsche Einschätzen der Lückengröße [Plavšić et al., 2010], sind mit die häufigsten Gründe für diese Unfälle. Um solche sicherheitskritischen Situationen zu verhindern, können Fahrassistenzsysteme entwickelt werden, welche die Abbiegeintention eines

Fahrers erkennen, damit das Fahrzeug rechtzeitig intervenieren kann. Ausgehend vom aktuellen Stand der Forschung soll die Integration von mehreren Datenquellen untersucht werden.

RQ1: Kann die Integration von Kontext-, Nutzer und neurophysiologischen Daten die Leistung von Modellen zur Intentionserkennung verbessern?

In Zusammenarbeit mit der Arbeitsgruppe *Angewandte Neurokognitive Psychologie* der Carl-von-Ossietzky Universität wurde eine Fahrsimulatorstudie mit gleichzeitiger Messung der Hirnaktivität der Proband:innen mithilfe von fNIRS durchgeführt [Unni et al., 2022]. Basierend auf den experimentellen Daten wurden zwei Modelle erstellt. Das erste Modell kombinierte Kontextinformationen und demographische sowie subjektive Fahrstildaten, um die Abbiegeintention der ProbandInnen zu klassifizieren [Trende et al., 2021]. Das zweite Modelle nutzte ebenfalls Kontextinformationen kombinierte diese jedoch mit neurophysiologischen Messdaten [Trende et al., 2022]. Hierbei konnte insbesondere gezeigt werden, dass die neurophysiologischen Daten bei der Klassifikation von sicherheitskritischen Abbiegemanövern hilfreich sein kann. Bei beiden Modellen wurde eine Feature Importance Analyse durchgeführt, um zu zeigen, dass die Integration der verschiedenen Datentypen hilfreich ist.

1.2.2 Unterschiede in der Interaktion bei der Mensch-HAV Interaktion

Bis ausschließlich vollautonome Fahrzeuge im Straßenverkehr fahren werden wird es einen hybriden Verkehr zwischen menschgesteuerten Fahrzeugen und HAV geben. Studien wie [Millard-Ball, 2018] legen nahe, dass es einen Unterschied bei der Mensch-HAV und der Mensch-Mensch Interaktion im Straßenverkehr gibt. Um sicherheitskritische Situationen zu vermeiden, welche aus solchen Unterschieden entstehen können, ist wichtig zu verstehen, wie Menschen mit HAV interagieren.

RQ2: Gibt es Unterschiede bei der Mensch-HAV Interaktion im Vergleich zu Mensch-Mensch Interaktionen?

In Zusammenarbeit mit der Arbeitsgruppe *Angewandte Neurokognitive Psychologie* der Carl-von-Ossietzky Universität wurden zwei Fahrsimulatorstudien durchgeführt, um etwaige Unterschiede bei der Interaktion mit HAV in zeitkritischen Abbiegesituationen zu untersuchen. In der ersten Studie konnte gezeigt werden, dass die Proband:innen unter Zeitdruck eine höhere Lückenakzeptanzwahrscheinlichkeit bei der Interaktion mit HAV haben [Trende et al., 2019b]. Die Ergebnisse der zweiten Studie kommen zu einem ähnlichen Ergebnis. Hierbei wurden zwei Modelle für die Interaktion zwischen menschlichen Fahrer:innen und HAV und menschlichen Fahrer:innen und anderen menschlichen Fahrer:innen entwickelt [Unni et al., 2022]. Die Auswertung der Modelle legt nahe, dass es für die Proband:innen einfacher war, die Abbiegeentscheidung bei der Interaktion mit HAV zu treffen. Allgemein suggerieren die Ergebnisse der Studien, dass Menschen die defensive Fahrweise eines autonomen Fahrzeuges in zeitkritischen Situationen ausnutzen könnten, um sich einen zeitlichen Vorteil zu verschaffen.

1.2.3 Unsicherheitserkennung bei der Nutzung von HAV

Für eine erfolgreiche Integration von autonomen Fahrzeugen in den Straßenverkehr muss die Technologie von den Nutzer:innen akzeptiert und verwendet werden. Hierfür sollte die Fahrt mit einem autonomen Fahrzeug so komfortabel wie möglich sein. Dies fördert Akzeptanz und Vertrauen in die Technologie [Paddeu et al., 2020] und kann die Einführung der Technologie in den Alltag beschleunigen. Diskomfort und Unsicherheit zu erkennen ist notwendig, um die Faktoren zu identifizieren, welche diese bei der Nutzung von HAV erzeugen. Hieraus leitet sich die erste in dieser Arbeit präsentierte Forschungsfrage ab:

RQ3: Kann die subjektive Unsicherheit einer Person bei der Nutzung eines autonomen Fahrzeugs mithilfe von physiologischen und Kontextinformationen klassifiziert werden?

Basierend auf Daten einer Fahrsimulatorstudie, welche von der TU Chemnitz durchgeführt wurde, konnte ein Modell zur Klassifikation von Unsicherheit bei Überholvorgängen im simulierten automatisierten Fahren erstellt werden [Trende et al., 2020]. Hierbei wurde ein Fokus auf die Integration von Kontext-, Nutzer- und physiologischen Messdaten gelegt. Es konnte gezeigt werden, dass eine solche Integration die Leistung des Modells zur Unsicherheitserkennung verbessert werden konnte [Trende et al., 2020]. Ein solches Modell kann als Grundlage für ein Fahrassistenzsystem dienen, welches die Fahrdynamik eines HAV dynamisch an das Komfortlevel der Nutzer:in anpasst.

1.2.4 Personalisierung von HAV Fahrstilen

Um Unsicherheit oder Diskomfort bei der Nutzung von hochautonomen Fahrzeugen zu vermeiden, kann der Fahrstil an die Präferenzen der Nutzer:in angepasst werden. Da Autofahren eine komplexe Aufgabe ist, kann sich der präferierte Fahrstil zwischen verschiedenen Menschen stark unterscheiden [Sagberg et al., 2015]. Eine Möglichkeit, damit sich das HAV optimal in Bezug auf die persönlichen Präferenzen der Nutzer:in verhält, ist somit die Anpassung des Fahrstils durch die Nutzer:in. Es stellt sich somit die folgende Forschungsfrage:

RQ4: Kann die Anpassung des Fahrstils eines HAV an die Präferenzen der Nutzer:in die Technologieakzeptanz erhöhen?

Hierzu wurde eine Fahrsimulatorstudie durchgeführt in der die Proband:innen die Möglichkeit hatten den Fahrstil eines simulierten HAV nach ihren Vorlieben anzupassen. Hierzu wurde die Technologieakzeptanz einer solchen Mensch-Maschine Schnittstelle mithilfe von zwei Fragebögen erhoben. Die Ergebnisse suggerieren, dass eine solche Schnittstelle die Akzeptanz von HAV erhöhen könnte und die Adoption der Technologie beschleunigen kann.

1.3 Forschungsmethoden

Eine Reihe unterschiedlicher Forschungsmethoden wurden für die in dieser Arbeit präsentierte Forschung verwendet. Empirische Forschungsmethoden umfassen hierbei Fahrsimulatorstudien (s. 2.4) und die Erhebung von Daten mithilfe von Fragebögen. Bei allen in dieser Arbeit beschriebenen empirischen Studien war der Autor dieser Arbeit bei der Planung, Umsetzung und der Durchführung der Studien maßgeblich beteiligt. Die Fahrsimulatorstudie, welche in Kapitel (5) beschrieben wird, wurde von MitarbeiterInnen der Forschungsgruppe *Allgemeine & Arbeitspsychologie* der TU Chemnitz durchgeführt. Der Autor dieser Arbeit war bei der Planung der Studie sowie Auswertung der Arbeit beteiligt. Mitarbeiter der Forschungsgruppe *Angewandte Neurokognitive Psychologie* der Carl-von-Ossietzky Universität Oldenburg haben bei der Durchführung der Fahrsimulatorstudie aus den Kapiteln 3 und 4 mitgewirkt. Dies betrifft insbesondere die Messung der Hirnaktivität während der Fahrsimulatorstudie mithilfe eines fNIRS Systems.

Die in den Studien erhobenen Messdaten wurden durch den Autor statistisch ausgewertet. Außerdem wurden Modellen aus dem Bereich des maschinellen Lernens (s. 2.5.1) mithilfe dieser Messdaten erstellt. Jegliche in dieser Arbeit beschriebenen Arbeiten zur Datenauswertung und Modellierung wurde vom Autor durchgeführt.

1.4 Aufbau der Arbeit

Kapitel 2 stellt wichtige Grundlagen für die präsentierten Forschungsarbeiten dar. Hierbei handelt es sich jeweils um eine kurze Einführung der verwendeten Forschungsmethoden und wichtige Referenzen zum aktuellen Stand der Forschung. Ein besonderer Fokus wird dabei auf die Grundlagen des maschinellen Lernens und die verwendeten Methoden gelegt.

Anschließend wird im Rahmen des ersten Anwendungsfalles die Forschungsarbeiten zu Forschungsfragen RQ1 und RQ2 dargestellt. Das Kapitel 3 stellt die Ergebnisse zweier unterschiedlicher Modellierungsansätze zur Klassifikation von Abbiegeverhalten von Fahrer:innen vor und umfasst somit die Arbeiten bezüglich RQ1. Hierbei steht insbesondere die Integration von Daten aus verschiedenen Datenquellen im

Vordergrund. In Kapitel 4 werden die Ergebnisse von zwei Fahrsimulatorstudien zur Interaktion von menschlichen Fahrer:innen und HAV in eben jenen Abbiegesituationen dargestellt. Dabei wird ein weiteres Modell zur Klassifikation des Abbiegeverhaltens im hybriden Verkehr präsentiert, wobei auch die Art des Interaktionspartners in die Modellierung miteinbezogen wird. Zusammenfassend umfasst das Kapitel 4 alle Forschungsarbeiten, welche sich mit der Forschungsfrage RQ2 befassen. Sowohl Kapitel 3 als auch Kapitel 4 schließen mit einem Fazit ab, welches die Ergebnisse der im Kapitel präsentierten Ergebnisse diskutiert.

Anschließend werden die Forschungsarbeiten zu Forschungsfrage RQ3 und RQ4 dargestellt. In Kapitel 5 werden die Ergebnisse der Modellierung von subjektiver Unsicherheit bei der Nutzung von HAV präsentiert. Hierbei handelt es sich um die Forschungsarbeiten, welche sich mit der Forschungsfrage RQ3 befassen. Kapitel 6 beschreibt die Ergebnisse der Fahrsimulatorstudie zur Personalisierung des Fahrverhaltens von automatisierten Fahrzeugen und umfasst somit die Forschungsergebnisse bezüglich Forschungsfrage RQ4.

Abschließend werden die Ergebnisse dieser Arbeit in Kapitel 7 mit Hinblick auf den wissenschaftlichen Kontext und Forschungsstand diskutiert. Des Weiteren werden Limitierungen der Arbeit und Ausblicke für mögliche Verbesserungen beziehungsweise Folgeprojekte gegeben. In Tabelle 1.1 findet sich zudem eine Übersicht über durchgeführte Experimente und erstellten Modelle.

Kapitel	Experiment (Experimentator)	Modell
3.3	Fahrsimulatorstudie + fNIRS (OFFIS & UOL)	Klassifikation von Abbiegeintention mithilfe von Bayesschen Netzen
3.4	s. 3.3	Klassifikation von Abbiegeintention mithilfe von künstlichen neuronalen Netzen
4.3	Fahrsimulatorstudie (OFFIS & UOL)	Statistische Auswertung des Abbiegeverhaltens
4.4	s. 4.3	Klassifikation des Abbiegeverhaltens mithilfe von Bayessches Netz
4.5	s. 4.3	Logistisches Modell des Abbiegeverhaltens
5	Fahrsimulatorstudie (TUC)	Klassifikation von Unsicherheit im automatisierten Fahren mithilfe von künstlichen neuronalen Netzen
6	Fahrsimulatorstudie (DLR-SE & UOL)	Statistische Auswertung der Fragebögen und Interaktion mit HMIs

Tabelle 1.1: Übersicht über die für diese Arbeit entworfenen und durchgeführten Studien und den Modellen, welche auf den experimentellen Daten entwickelt wurden.

1.5 Publikationen

1.5.1 Relevante Erstautorenpublikationen für diese Arbeit

- Trende, A., Unni, A., Weber, L., Rieger, J. W., & Luedtke, A. (2019, June). An investigation into human-autonomous vs. human-human vehicle interaction in time-critical situations. In Proceedings of the 12th ACM International Conference on Pervasive Technologies Related to Assistive Environments (pp. 303-304).
- Trende, A., Gräfin, D., & Weber, L. (2019, September). Personalized user profiles for autonomous vehicles. In Proceedings of the 11th International Conference on Automotive User Interfaces and Interactive Vehicular Applications: Adjunct Proceedings (pp. 287-291).
- Trende, A., Hartwich, F., Schmidt, C., & Fränzle, M. (2020, July). Improving the detection of user uncertainty in automated overtaking maneuvers by combining contextual, physiological and individualized user data. In International Conference on Human-Computer Interaction (pp. 390-397). Springer, Cham.
- Trende, A., Unni, A., Rieger, J., & Fraenzle, M. (2021, July). Modelling Turning Intention in Unsignalized Intersections with Bayesian Networks. In International Conference on Human-Computer Interaction (pp. 289-296). Springer, Cham.
- Trende, A., Krefting, I., Unni, A., Rieger, J. W., Fränzle, M. (2022). A Case-Study for a Human-Centered Approach to Traffic Management Systems. In International Conference on Human-Computer Interaction (pp. 259-266). Springer, Cham.
- Trende, A., Unni, A., Jablonski, M., Biebl, B., Lüdtkke, A., Fränzle, M., Rieger, J. W. (2022). Driver's turning intent recognition model based on brain activation and contextual information. *Frontiers in Neuroergonomics*, 23.

1.5.2 Relevante Koautorenpublikationen

- Damm, W., Fränzle, M., Lüdtke, A., Rieger, J. W., Trende, A., & Unni, A. (2019, June). Integrating Neurophysiological Sensors and Driver Models for Safe and Performant Automated Vehicle Control in Mixed Traffic. In 2019 IEEE Intelligent Vehicles Symposium (IV) (pp. 82-89). IEEE.
- Sowe, S. K., Fränzle, M., Osterloh, J. P., Trende, A., Weber, L., & Lüdtke, A. (2019, September). Challenges for Integrating Humans into Vehicular Cyber-Physical Systems. In International Conference on Software Engineering and Formal Methods (pp. 20-26). Springer, Cham.
- Drewitz, U., Ihme, K., Oehl, M., Schrödel, F., Voßwinkel, R., Hartwich, F., ... & Lüdtke, A. (2019). Automation ohne Unsicherheit: Vorstellung des Förderprojekts AUTOAKZEPT zur Erhöhung der Akzeptanz automatisierten Fahrens.
- Drewitz, U., Ihme, K., Bahn Müller, C., Fleischer, T., La, H., Pape, A. A., ... & Trende, A. (2020, July). Towards user-focused vehicle automation: the architectural approach of the AutoAkzept project. In International Conference on Human-Computer Interaction (pp. 15-30). Springer, Cham.
- Niermann, D., Trende, A., & Luedtke, A. (2020, July). Tracking and Evaluation of Human State Detections in Adaptive Autonomous Vehicles. In International Conference on Human-Computer Interaction (pp. 378-384). Springer, Cham.
- Brück, Y., Niermann, D., Trende, A., & Lüdtke, A. (2021, February). Investigation of Personality Traits and Driving Styles for Individualization of Autonomous Vehicles. In International Conference on Intelligent Human Systems Integration (pp. 78-83). Springer, Cham.
- Krefting, I., Trende, A., Unni, A., Rieger, J., Luedtke, A., & Fränzle, M. (2021, September). Evaluation of graphical human-machine interfaces for turning manoeuvres in automated vehicles. In 13th International Conference on Automotive User Interfaces and Interactive Vehicular Applications (pp. 77-80).

-
- Unni, A., Trende, A., Pauley, C., Biebl, B., Kacianka, S., Lüdtke, A., ... & Rieger, J. W. Decision making in human-autonomous vehicle interaction.
 - Niermann, D., Trende, A., Ihme, K., Drewitz, U., Hollander, C., & Hartwich, F. (2021). An Integrated Model for User State Detection of Subjective Discomfort in Autonomous Vehicles. *Vehicles*, 3(4), 764-777.
 - Unni, A., Trende, A., Pauley, C., Weber, L., Biebl, B., Kacianka, S., Lüdtke, A., Bengler, K., Pretschner, A., Fränzle, M. and Rieger, J. W. (2022, February). Investigating Differences in Behavior and Brain in Human-Human and Human-Autonomous Vehicle Interactions in Time-Critical Situations. In *Frontiers in Neuroergonomics*.
 - Koopmann B., Trende A., Rothemann K., Feeken L., Suchan J., Johannmeyer D. and Brück Y. (2022). Challenges in Achieving Explainability for Cooperative Transportation Systems. 2022 IEEE 30th International Requirements Engineering Conference Workshops (REW)
 - Drewitz, U., Ihme, K., Oehl, M., Hartwich, F., Hollander, C., Voßwinkel, R., ... Niedling, M. (2022). Meeting User Needs in Vehicle Automation. *Human Factors in Transportation*, 60, 40.

Kapitel 2

Grundlagen

2.1 Zustands- und Intentionserkennung beim Autofahren

Die Modellierung und Prädiktion von Nutzerzuständen oder Nutzerintentionen wurde in der Vergangenheit vielfach für Domänen wie die Arbeitssicherheit [Hernandez et al., 2011, Jebelli et al., 2018], Flugverkehr [Feng et al., 2018, Masters and Schulte, 2022] oder Autofahren [Green, 1994, Unni et al., 2015, Yan et al., 2017] erforscht. Bei der Modellierung von Nutzerzuständen sollen meist potenziell gefährliche Zustände, wie Erschöpfung (*fatigue*), hohe kognitive Arbeitslast (*cognitive workload*) oder Stress gemessen oder vorhergesagt werden.

Bei der Intentionserkennung geht es vor Allem darum, Handlungen eines Menschen vorherzusagen beziehungsweise das Entscheidungsverhalten des Menschen in einer bestimmten Situation zu modellieren. Ein Beispiel hierfür wäre das Erkennen eines geplanten Spurwechsels beim Autofahren. Hierbei könnte die Fahrer:in gewarnt werden, falls ein sicherheitskritischer Spurwechsel erkannt wird. Ein weiteres Beispiel für Interventionsstrategien wäre, dass ein Fahrerassistenzsystem die Steuerung über das Fahrzeug übernimmt, um eine gefährliche Situation zu verhindern beziehungsweise einen Unfall zu vermeiden.

Einer der populärsten Bereiche der Forschung zu Nutzerzustandserkennung fokussiert sich auf das Messen und Erkennen von hoher kognitiver Arbeitslast [Green, 1994, Unni et al., 2015, van Gent et al., 2018, Yan et al., 2017, Yi et al., 2018]. Hohe kognitive Arbeitslast kann zu Fehlern bei der Durchführung von Aufgaben führen [Oviatt, 2006]. Erschöpfung ist ein weiteres wichtiges Anwendungsfeld für Nutzerzustandserkennung beim Autofahren [Hajinoroozi et al., 2016, Zhou et al., 2020]. Ermüdung kann Fehler bei der Fahrzeugführung verursachen und somit auch zu sicherheitskritischen Situationen führen [Zhang et al., 2016]. Ein Modell zur Erkennung von Ermüdung könnte genutzt werden, um die Fahrer:in auf die Ermüdung aufmerksam zu machen, damit die Fahrt pausiert wird. Stress beim Autofahren kann nicht nur zu sicherheitskritischen Situationen führen, sondern auch den Fahrkomfort reduzieren und somit negative Assoziationen mit der Nutzung des Fahrzeugs bei der Fahrer:in hervorrufen. Modelle zur Nutzerzustandserkennung können somit genutzt werden, um stressinduzierende Situationen im Straßenverkehr zu identifizieren [Bianco et al., 2019]. Im Fall von automatisierten Fahrzeugen kann ein solches Modell verwendet werden, um herauszufinden, welches automatisierte Fahrverhalten für eine Nutzer:in Stress induziert beziehungsweise unkomfortabel ist [Healey and Picard, 2000, Healey and Picard, 2005, Beggiato et al., 2018, Chung et al., 2019].

Ein großer Teil der Unfälle im Straßenverkehr lassen sich auf menschliche Fehler zurückführen [Treat et al., 1979]. Ein wichtiger Faktor ist hierbei das falsche Einschätzen von Geschwindigkeiten oder generell das Verhalten von anderen VerkehrsteilnehmerInnen [Treat et al., 1979]. Solche sicherheitskritischen Entscheidungen beziehungsweise Fahrmanöver können durch eine Intentionserkennung erkannt werden. Anschließend kann eine Interventionsstrategie initiiert werden. Mögliche Interventionsstrategien sind zum einen die Kommunikation beziehungsweise Warnung der Fahrer:in. Auch ein direkteres Eingreifen in die Fahrdynamik, wie zum Beispiel das Einleiten einer Notbremsung, ist denkbar.

Intentionserkennung beim Autofahren wurde in der Vergangenheit bereits von vielen Forschergruppen untersucht [Liu and Salvucci, 2001, Berndt et al., 2008, Olabiyi et al., 2017, Ba et al., 2017]. Das Ziel hierbei ist meist die Entwicklung und Verbesserung von Fahrassistenzsystemen. [Liu and Salvucci, 2001] präsentieren eine Methodik, um Fahrverhalten und Intention einer Fahrer:in zu modellieren und vor-

herzusagen. Die Forscher:innen argumentieren, dass sich die Intention einer Fahrer:in anhand der aktuellen Lenkbewegungen, dem Blickverhalten und Informationen über die aktuelle Verkehrssituation vorhersagen lässt.

Meist werden diese Zustände beziehungsweise Intentionen mithilfe von statistischen Verfahren modelliert. Heutzutage sind besonders Modelle aus dem Bereich des maschinellen Lernens weit verbreitet. Auf diese Art der Modellierung wird im Abschnitt 2.5.1 eingegangen. Die für diese Modelle verwendeten Daten können mit einer Vielzahl verschiedener Sensoren erhoben werden. In den folgenden Abschnitten werden insbesondere neuro- und psychophysiologische Messverfahren genauer erläutert. Weitere wichtige Sensorquellen erfassen unter Anderem Kontextinformationen, wie zum Beispiel Informationen über andere Verkehrsteilnehmer. Solche Daten können etwa mithilfe von Methoden zur Umfelderkennung, wie LIDAR oder Kameras, aufgezeichnet werden. Des Weiteren können Informationen über die Fahrdynamik des Fahrzeuges verwendet werden. Diese Daten können direkt über den CAN-Bus ausgelesen und verwendet werden.

2.2 Psychophysiologische Messverfahren

Psychophysiologische Messverfahren sind eine der gängigsten Messverfahren zur Nutzerzustands- und Intensionserkennung. Allgemein gibt es eine Vielzahl unterschiedlicher psychophysiologischen Messverfahren. Grundlegend werden hierbei Änderungen physiologischer Eigenschaften des Menschen gemessen. Das Ziel ist die Änderungen aufzuzeichnen, welche mit einer Veränderung des Nutzerzustands oder Verhaltens korrelieren. Basierend auf diesen Messdaten können anschließend Modelle entwickelt werden, welche die Änderungen des Nutzerzustands oder Verhaltens erkennen oder vorhersagen. Selbstauskünfte einer Proband:in über ihren Zustand können durch Emotionen oder Affekte verzerrt sein. Psychophysiologische Messverfahren bieten hingegen eine direktere Messung dieser Zustände, da die so gemessenen Indikatoren meist nicht unter bewusster Kontrolle der Proband:Innen stehen, sondern vom sympathischen Nervensystem gesteuert werden. Die wichtigsten Indikatoren für solche Zustands- oder Verhaltensänderungen sind die Erhöhung der Herzfrequenz (Pulsfrequenzmessung), das

Blickverhalten und Pupillendurchmessers (Blickerfassung und Pupillometrie) und die Änderung des elektrischen Hautleitwiderstands (Messung elektrodermalen Aktivität). Heutzutage gibt es für diese Messverfahren bereits handliche Sensorik, welche von Nutzer:innen ohne großen Störfaktor während eines Experiments oder des Alltags verwendet werden kann (s. Abb. 2.1).

Sowohl in Realfahr- wie auch Fahrsimulatorstudien wurden Herzrate (HR) und Herzratenvariabilität (HRV) als Indikatoren für Anstrengung, Stress und Workload identifiziert [Dijksterhuis et al., 2011, Mehler et al., 2012, Mehler et al., 2012]. In der Regel steigt die HR und die HRV sinkt bei stressigen Situationen oder anspruchsvollen Aufgaben. HRV ist ein Indikator für die Aktivität des parasympathischen und sympathischen Nervensystems [Thayer and Lane, 2009]. Eine niedrige HRV ist ein Indikator für Aktivität des sympathischen Nervensystems, was wiederum in Verbindung mit Stress beziehungsweise hoher kognitiver Last steht [Solhjoo et al., 2019]. [Beggiato et al., 2018] verwendete HR und HRV in Fahrsimulatorstudien, um die subjektive Unsicherheit der Proband:innen während einer simulierten autonomen Fahrt zu untersuchen. In dieser Studie verringerte das autonome Fahrzeug den Abstand zu einem vorrausfahrenden LKW zunehmend. Dies sollte Unsicherheit bezüglich des sicheren Fahrverhaltens des autonomen Fahrzeuges bei den Proband:innen erzeugen. Wie erwartet sank die HRV der Proband:innen beim Auffahren auf den vorrausfahrenden LKW was wiederum ein steigendes Stresslevel bei den Proband:innen suggeriert.

Die Hautleitfähigkeit beziehungsweise elektrodermale Aktivität ist ein weiterer psychophysiologischer Indikator, welcher gemessen wird, um Stress oder kognitive Arbeitslast zu erkennen [Dawson et al., 2017, Morris et al., 2017]. Die Hautleitfähigkeit steigt mit zunehmendem Stress und Schwierigkeit der kognitiven Aufgaben. Grundlegend hierfür ist, dass das sympathische Nervensystem die Schweißsekretion und Blutfluss bei Stress erhöht. Hierdurch vergrößert sich unter Stress entsprechend die Hautleitfähigkeit.

Auch Eye Tracker sind seit vielen Jahrzehnten ein gängiges Messgerät in Studien in der Stress- und Workloadforschung. Hierbei wird der Blickpunkt, der Pupillendurchmesser und die Blinzelfrequenz, als Indikatoren für Stress und kognitive Arbeitslast untersucht [Andreassi, 2010, Cowley et al., 2016, Beggiato et al., 2018]. Viele Stu-

dien zeigen, dass der Pupillendurchmesser sich bei schweren Aufgaben mit hohem kognitiven Workload vergrößert [Boucsein and Backs, 2000, Andreassi, 2010, Cowley et al., 2016]. Dies führt zu der Hypothese, dass der Pupillendurchmesser auch für Experimente zur Messung von Stress und Unsicherheit genutzt werden kann [Beggiato et al., 2018]. Es konnte zudem gezeigt werden, dass die Blinzelfrequenz ein Indikator für die Schwierigkeit einer Aufgabe und dem kognitiven Workload sind [Andreassi, 2010, Cowley et al., 2016]. [Backs et al., 2000] haben gezeigt, dass die Blinzelfrequenz bei komplexen Situationen beim Autofahren abnimmt.

Es gilt zu beachten, dass psychophysiologische Messverfahren zwar die Änderung eines Indikators messen können, jedoch können die Gründe für diese Änderungen vielfältig sein und werden unter Umständen nicht von dem im Experiment präsentierten Stimulus verursacht. Neuroimaging Methoden haben das Potential zu einer genaueren Bestimmung von Nutzerzuständen durch die direkte Messung von Gehirnaktivität. Die Grundlagen für diese Methoden werden im folgenden Kapitel eingeführt.

2.3 Neuroimaging

Neuroimaging bezeichnet bildgebende Messverfahren des Nervensystems. Sie erlauben die strukturelle und funktionelle Untersuchung des zentralen Nervensystems und werden meist zur Studie des menschlichen Gehirns verwendet [Savoy, 2001]. Eine wichtige Grundlage vieler Neuroimaging Verfahren ist die sogenannte Hämodynamik, welche die Dynamik des Blutflusses in Gefäßen beschreibt. Hierbei wird die Hämoglobinkonzentration im Hirngewebe gemessen, welche mit der neuronalen Aktivität im entsprechenden Hirnareal korreliert. In dieser Arbeit wurde in einem Experiment funktionelle Nahinfrarotspektroskopie (fNIRS - *functional near-infrared spectroscopy*) zur Messung der Hirnaktivität der Proband:innen verwendet. Weitere populäre Neuroimaging Methoden sind die Magnetresonanztomographie (MRT), Elektroenzephalografie (EEG) und Magnetoenzephalographie (MEG).

fNIRS ist ein nichtinvasives Neuroimaging Verfahren, welches verwendet wird, um die Funktionsweise und Aktivität des menschlichen Cortex zu untersuchen. Wie oben beschrieben werden hierbei Änderungen der Hämoglobinkonzentration gemessen. Ei-



Abbildung 2.1: Links oben: Herzfrequenzmessgerät [Commons, 2009]. Rechts oben: Sensor zur Messung der elektrodermalen Aktivität [Zyto, 2022]. Links unten: Eye Tracker [Commons, 2014]. Rechts unten: Druckmatte für den Autositz [Sensors, 2022].

ne wichtige Grundlage für die Entwicklung der ersten fNIRS Geräte war Frans Jobsis Entdeckung, dass Hirngewebe ein hohes Level an Transparenz im Nahinfrarotbereich hat [Jobsis, 1977]. Dieses Erkenntnis ermöglichte die Echtzeitmessung der Hämoglobinkonzentration im Hirngewebe mithilfe von Licht im Nahinfrarotbereich [Ferrari et al., 1980, Wyatt et al., 1986], wobei Änderungen in der Lichtabsorption im Blutfluss gemessen werden [Delpy and Cope, 1997]. Ein Vorteil von fNIRS und Neuroimaging Verfahren im Allgemeinen ist, dass sie nichtinvasive und direktere Messverfahren sind. Subjektive Angaben von Proband:innen können durch eine Vielzahl von Faktoren, wie kognitive Biases oder soziale Normen beeinflusst werden. Neuroimaging bietet, wie auch die psychophysiologischen Messverfahren, eine direktere und idealerweise unvoreingenommene Methode zur Messung von Zuständen und Intensionen der Proband:innen. Ein weiterer wichtiger Vorteil beider Messverfahren ist, dass sie im Gegensatz zu Aussagen der Proband:innen, kontinuierlich gemessen werden können. In einer stressigen Situation kann eine Proband:in vergessen Rückmeldung zu geben. In diesem Fall wäre eine kontinuierliche Messung mithilfe eines der genannten Messverfahren von Vorteil.

Neuroimaging Verfahren wurde in den letzten Jahrzehnten bereits vielfach für die Forschung im Bereich des Autofahrens verwendet [Haghani et al., 2021]. Anwendungsbereiche sind hierbei sowohl die Zustand- als auch die Intensionserkennung. Sowohl [Khan and Hong, 2015], als auch [Ahn et al., 2016] präsentierten passive Gehirn-Computer Schnittstellen zur Müdigkeitserkennung beim Autofahren mithilfe von fNIRS. Studien wie z.B. [Unni et al., 2015, Shimizu et al., 2009, Herff et al., 2017] untersuchten die kognitive Arbeitslast beim Autofahren mithilfe von fNIRS. Des Weiteren wurde fNIRS vielfach für die Intensionserkennung beim Fahren verwendet [Haghani et al., 2021]. Hierzu zählen die Intensionserkennung von (Not-)bremsungen [Hernández et al., 2018, Haufe et al., 2014, Haufe et al., 2011, Kim et al., 2014], Beschleunigen [Vecchiato et al., 2019] oder Abbiegen [Zhang et al., 2015].

In den letzten Jahren wurde bereits großer Fortschritt in der Entwicklung von tragbaren neurophysiologischen Messsystemen, wie EEG [Casson, 2019] und fNIRS [Piper et al., 2014] gemacht. Diese ermöglichen auch die Aufnahme von Hirnaktivität während alltäglichen Handlungen, wie dem Autofahren. Trotzdem werden die meisten Neuroimaging Studien für den Anwendungsfall des Autofahrens in einem Fahrsimula-

tor durchgeführt. Grund hierfür sind vor Allem, dass die experimentellen Bedingungen sehr genau kontrolliert werden können und, dass präzisere neurophysiologische Messsysteme nicht portabel sind. Im Folgenden Kapitel wird ein Überblick über die Grundlagen von Fahrstudien gegeben.

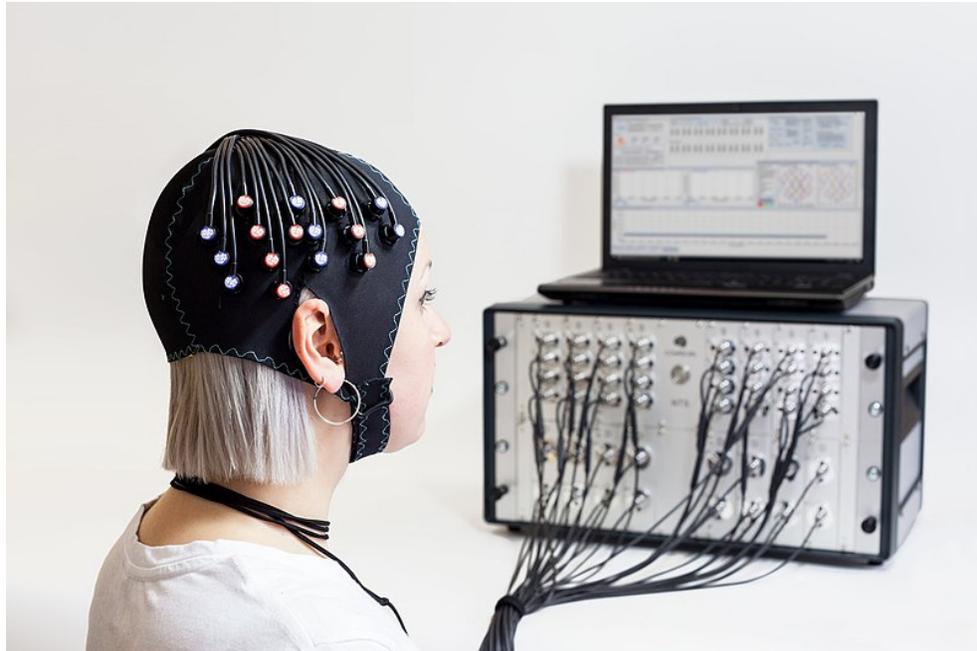


Abbildung 2.2: Probandin mit fNIRS Kappe. [Commons, 2019]

2.4 Fahrstudien

Fahrstudien wurden erstmals in den 1950er Jahren verwendet um das Fahrverhalten von Menschen in einer virtuellen Umgebung zu untersuchen. Das prominenteste Beispiel hierfür war der Drivotrainer von Aetna [Peek, 2018]. Bedingt durch den technologischen Fortschritt im Bereich der Rechnertechnik wurden in den kommenden Jahrzehnten mehr und mehr Fahrstudien in der Automobilindustrie, an Universitäten und Forschungsinstituten verwendet [Blana, 1996].

Fahrstudien haben in der einfachsten Ausführung drei essentielle Komponenten:

Jeder Fahrstudien besitzt ein Gerät zur Darstellung der Fahrstudien. Dies kann ein Monitor, eine Leinwand inklusive Beamer oder eine Virtual-Reality Brille sein [Schultheis et al., 2007]. Des Weiteren besitzt jeder Fahrstudien ein Gerät für Steuerung des virtuellen Fahrzeuges durch die Nutzer:in. Im einfachsten Fall kann dies eine Tastatur sein. In der Regel besitzen jedoch die meisten Fahrstudien ein Lenkrad und Brems- und Gaspedale. In seltenen Fällen wird zudem ein Kupplungspedal und Schalthebel verwendet. In umfangreicheren Studien sind diese Eingabegeräte in einem sogenannten Fahrzeug-Mockup integriert. Ein Fahrzeug-Mockup bezeichnet hier ein Fahrzeug beziehungsweise Teile eines Fahrzeuges, in der die Proband:innen sich während einer Studie aufhalten (s. 2.3). Ein solches Mockup soll die Immersion der Fahrstudien vergrößern. Dieses Fahrzeug-Mockup kann statisch sein oder sich auf einer bewegbaren Plattform befinden. Ein dynamischer Fahrstudien verspricht ein realistischeres, virtuelles Fahrgefühl indem er versucht durch Bewegung die physikalischen Kräfte, welche bei einer echten Autofahrt auftreten würden, zu replizieren. Hierdurch kann unter Umständen auch das Auftreten von Bewegungskrankheit, welches bei statischen Fahrstudien häufiger der Fall ist, verhindert werden [Blana, 1996]. Die letzte essentielle Komponente eines Fahrstudien ist die Fahrstudiensoftware. Diese verarbeitet die Eingabe der Nutzer:innen, wie Lenken oder das Drücken des Gaspedals, und überträgt sie in die virtuelle Umgebung. Die Fahrstudiensoftware übernimmt entsprechend auch die Simulation der virtuellen Umgebung beziehungsweise des simulierten Verkehrsszenarios. Hierbei müssen nicht nur das Fahrverhalten des virtuellen Fahrzeuges, welches durch die Proband:in gesteuert wird, simuliert und abgebildet werden, sondern auch das Verhalten aller anderen virtuellen Verkehrsteilnehmer. Einige Fahrstudiensoftwares bieten zudem die Möglichkeit mehrere Fahrstudien zu verbinden und somit Experimente mit mehreren Proband:innen durchzuführen. In der Regel bieten Fahrstudiensoftwares noch Softwarekomponenten zur Erstellung der Verkehrsszenarios mithilfe einer grafischen Benutzeroberfläche. Beispiele für populäre Fahrstudiensoftwares sind SILAB [Krüger et al., 2005], CarMaker [Automotive, 2022] und CARLA [Dosovitskiy et al., 2017].

Fahrstudien bieten einige große Vorteile gegenüber Realfahrstudien. Der erste Vorteil ist die Reproduzierbarkeit von experimentellen Bedingungen [Zhang et al.,

2020]. Fahrstudien nutzen in der Regel eine Softwarekomponente, um das Design der Verkehrssituation zu beschreiben. Diese Verkehrssituationen können sowohl randomisierte wie auch deterministische Elemente enthalten. So kann ein bestimmtes computergesteuertes Fahrzeug immer zum gleichen Zeitpunkt in der Simulation erscheinen. Auf diese Weise lässt sich für jeden Versuchsdurchlauf die gleiche Abbiegesituation mit der gleichen Lückengröße reproduzieren. Ein weitere wichtiger Vorteile ist, dass Fahrstudien eine sichere Umgebung für die Proband:innen und ExperimentatorInnen bietet [Zhang et al., 2020]. Dies ist insofern wichtig für Studien, welche sicherheitskritische Situationen, wie Abbiege- oder Einfädelmanöver, untersuchen [Blana, 1996].

Es muss jedoch auch erwähnt werden, dass die Validität von Fahrstudien immer noch diskutiert wird [Blana, 1996, Kaptein et al., 1996, De Winter et al., 2007, Branzi et al., 2017, Wynne et al., 2019, Luzuriaga et al., 2021]. Selbst der technisch fortschrittlichste Fahrstudien kann die Erfahrung einer realen Autofahrt nicht vollständig replizieren. Dies liegt unter Anderem an den fehlenden beziehungsweise nur nachgestellten, physikalischen Kräften bei der Nutzung eines Simulators [Kaptein et al., 1996, Blana, 1996, Wynne et al., 2019]). Trotz der sich stets verbessernden Darstellung beziehungsweise Grafik der virtuellen Umgebung ist der Unterschied zu einer realen Verkehrssituation deutlich erkennbar. Zuletzt ist es wichtig zu erwähnen, dass die Immersion einer Fahrstudien leicht durch einen virtuellen Unfall gestört werden kann.

Die in dieser Arbeit präsentierten Studien wurden mithilfe des Fahrstudien der Carl-von-Ossietzky Universität, Oldenburg (s. Fig. 2.3) und dem Fahrstudien der Technischen Universität Chemnitz durchgeführt. Der Fahrstudien der Universität Oldenburg besitzt ein Sichtfeld von 150° und der Simulator der TU Chemnitz hat ein Sichtfeld von 180° . Beide Fahrstudien haben ein realitätsgetreues, statisches Fahrzeugmockup. Die Simulatoren sind mit einem Lenkrad und Gas- sowie Bremspedal ausgestattet. SILAB [Krüger et al., 2005] wurde als Simulationssoftware für alle Studien verwendet. SILAB kann die Fahrdynamik, wie Geschwindigkeit und Beschleunigung, während des Experiments aufzeichnen. Außerdem bietet SILAB die asynchrone Kommunikation zwischen verschiedenen DPUs. DPUs sind Module, welche die Funktionalität der Simulationssoftware erweitern und speziell für Studi-

en programmiert werden können. Mithilfe von DPUs können zum Beispiel Mensch-Maschine-Schnittstellen sowie Fahrerassistenzsysteme implementiert werden. Außerdem können (neuro-)physiologische Sensoren (s. 2.2 & 2.3) mithilfe von DPUs mit der Simulationssoftware synchronisiert werden.



Abbildung 2.3: Fahrstudien der Carl-von-Ossietzky Universität Oldenburg

Vor dem eigentlichen Experiment absolvieren die Proband:innen in der Regel eine Trainingsfahrt. Diese Trainingsfahrt dauert meist 10 bis 15 Minuten und soll ihnen helfen sich an die virtuelle Simulationsumgebung und die Fahrdynamik des Fahrzeuges zu gewöhnen. Fahrstudien können bei etwa 10-20% der Proband:innen Bewegungskrankheit hervorrufen. Für die Teilnahmen an einer Fahrstudie müssen die Proband:innen einen gültigen Führerschein besitzen, da die simulierten Verkehrsszenarien sich am lokalen Straßenverkehr orientieren. Des Weiteren erhalten alle Proband:innen eine monetäre Belohnung für ihre Teilnahme an den Studien. Die in dieser Arbeit präsentierten experimentellen Studien wurden

vor der Durchführung von der Kommission für Forschungsfolgenabschätzung und Ethik der Carl-von-Ossietyky Universität geprüft.

2.5 Maschinelles Lernen

2.5.1 Einführung

Wie bereits in Kapitel 2.1 beschrieben, wird für Nutzerzustands- oder Intentionserkennungsmodelle nicht nur Sensorik sondern auch ein Modell benötigt, welches aus den Messdaten der Sensorik einen Zustand oder Intention schätzt. Hierbei werden in der Regel statistische Modelle, wie Modelle des maschinellen Lernens verwendet. Maschinelles Lernen (*Machine Learning*) hat in den letzten Jahrzehnten Anwendung in vielen Bereichen gefunden. Klassischerweise liegt einem Machine Learning Modell ein Datensatz bestehend aus Datenpunkten von mehreren Variablen zu Grunde. Meist soll anhand einer Menge dieser Variablen (*Features*) eine oder mehrere weitere Variable dieses Datensatz vorhersagt werden. Machine Learning Modelle versuchen diese Input-Output Relation zwischen den Variablen zu modellieren.

In Abbildung 2.4 findet sich ein Beispiel für einen klassischen Anwendungsfall für maschinelles Lernen basierend auf dem sogenannten *Iris* Datensatz . Hierbei sind die Datenpunkte der Feature Kelchblattweite gegen Kelchblattlänge für die zwei Arten *Iris Setosa* (blau) und *Iris Versicolor* (orange) aufgetragen. Die gestrichelte Linie symbolisiert ein hypothetisches, lineares Modell, welches den Datensatz entsprechend der beiden Arten fast perfekt separiert. Hierbei handelt es sich um ein Klassifikationsmodell. Neben Klassifikationsmodellen gibt es auch sogenannte Regressionsmodelle. Hierbei wird anhand einer Menge an Inputfeatures nicht eine diskrete Klasse vorhergesagt, sondern ein kontinuierlicher Wert der Outputvariable.

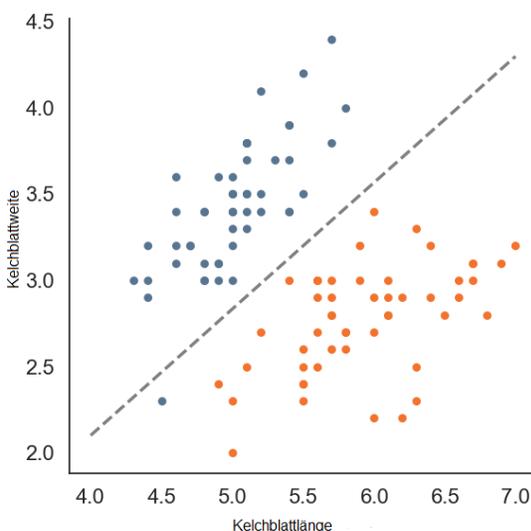


Abbildung 2.4: Klassifikation von Schwertlilienarten anhand ihrer Morphologie mithilfe des sogenannten *Iris* Datensatzes [Fisher, 1936]. In dieser Abbildung wurde die Kelchblattweite gegen die Kelchblattlänge für die *Iris Setosa* (blau) und *Iris Versicolor* (orange) aufgetragen. Ein hypothetisches lineares Klassifikationsmodell (graue Linie) kann die beiden Arten bzgl. der dargestellten Eigenschaften bis auf einen Datenpunkt richtig klassifizieren.

2.5.2 Training von Machine Learning Modellen

Jedes Machine Learning Modell muss an die verwendeten Daten angepasst beziehungsweise trainiert werden. Ein Modell besitzt mehrere freie Parameter, welche iterativ verändert werden, sodass der Fehler zwischen dem Output des Modells und der Zielvariable minimiert wird. Dies geschieht in der Regel mithilfe einer sogenannten Trainingsmenge des Datensatzes. Nach Beendigung des Trainings wird das Modell auf einer Testmenge evaluiert. Diese Testmenge wird nicht im Training verwendet. Würde man das Modell auf dem Gesamtdatensatz trainieren und evaluieren würde das Modell mit hoher Wahrscheinlichkeit an diesen überangepasst werden (*overfit-*

ting) (s. Abb. 2.5). Dies bedeutet, dass das Modell auf diesen Daten eine sehr gute Performance aufweist, jedoch nicht sehr gut für neue Daten funktionieren wird. In der Regel soll ein Modell so generalisierbar wie möglich sein und somit auch mit Daten funktionieren, welche nicht in der Trainingsmenge vorhanden waren. Ein weiterer Grund, welcher zu Overfitting führen kann ist, dass ein Modell zu viele Freiheitsgrade beziehungsweise freie Parameter hat und sich das Modell zu gut an den Datensatz anpasst. Im Gegensatz zum Overfitting kann es auch vorkommen, dass ein Modell unterangepasst (*underfitting*) (s. Abb. 2.5) ist und somit die Komplexität der gegebenen Daten nicht abbilden kann. Dies kann beispielsweise passieren, wenn ein lineares Modell für ein nicht-lineares Problem trainiert wird. Ein weiterer Grund hierfür kann sein, dass das Modell nicht ausreichend lange für das gegebene Problem trainiert beziehungsweise optimiert wurde.

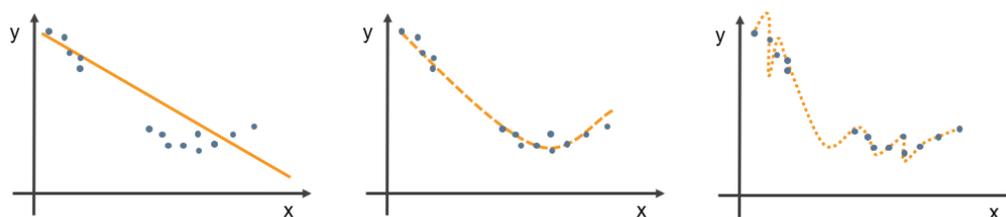


Abbildung 2.5: Drei verschiedene Modelle (orange) welche für die Datenpunkte (blau) trainiert wurden. **Links:** Underfitting: Ein lineares Modell, welches nicht komplex genug für die Daten ist. **Mitte:** Ein Modell mit ausreichender Komplexität. **Rechts:** Overfitting: ein Modell mit zu hoher Komplexität.

Mithilfe von Regularisierung können Over- beziehungsweise Underfitting verhindert werden. Hierbei wird der Fehlerfunktion des Modells ein weiterer Term hinzugefügt. Dieser Term besteht aus dem Regularisierungskoeffizienten λ und einer Regularisierungsfunktion $R(w)$. Häufig wird hierbei die L_2 Regularisierung verwendet [Hastie et al., 2009]. Die Regularisierungsparameter λ kann frei gewählt und optimiert werden. Ein großes λ führt zu einer Präferenz für simple Modelle, was zu Underfitting führen kann. Entsprechend kann ein kleines λ zu Overfitting führen.

Um Overfitting zu verhindern können außerdem Kreuzvalidierungsverfahren verwendet werden. Eines der gängigsten Kreuzvalidierungsverfahren ist die sogenannte k -fold Kreuzvalidierung [Hastie et al., 2009]. Der Gesamtdatensatz wird hierbei zuerst zufällig permutiert und anschließend in k gleichgroße Teildatensätze unterteilt. Anschließend wird das Modell auf $k - 1$ Teildatensätzen trainiert und anschließend auf dem verbleibenden Teildatensatz evaluiert (s. Abb. 2.6). Das Training und Evaluation wird k mal wiederholt, sodass jeder der k Teildatensätze einmal als Testdatensatz verwendet wurde. Abschließend können Mittelwerte für die gewünschten Metriken ermittelt werden.

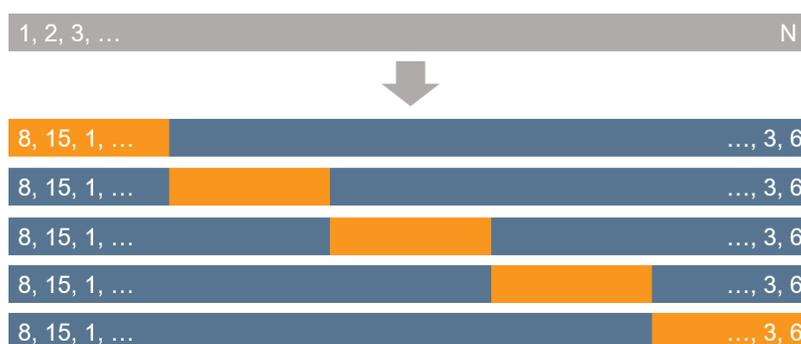


Abbildung 2.6: Schematische Darstellung der k -Fold Kreuzvalidierung. Der Datensatz (grau) wird in fünf verschiedene Variationen an Training- (blau) und Testdatensätze (orange) aufgeteilt [Hastie et al., 2009].

2.5.3 Evaluation von Klassifikationsmodellen

Gängige Metriken für die Evaluation von Klassifikationsmodellen sind die *Accuracy*, die Wahr-Positiv Rate (*Sensitivität*), die Falsch-Positiv Rate und die Fläche unter der sogenannten Receiver Operating Characteristic (*ROC*), welche als *Area-under-Curve* (*AUC*) bezeichnet wird. Die folgenden Größen müssen berechnet werden, um die Accuracy eines binären Klassifikators zu berechnen: Die Richtig-Positiven (*True Positive* - TP) bezeichnen diejenigen Instanzen des Datensatzes für die sowohl der Klassifikator als auch die *Ground Truth* positiv sind. Die *Ground Truth* bezeich-

net die wahre Klasse einer Instanz des Datensatzes. Entsprechend sind die Richtig-Negativen (*True negatives* - TN) alle Instanzen in denen sowohl die Klassifikation als auch die *Ground Truth* negativ sind. Falsch-Negative (*False negative* - FN) und Falsch-Positive (*false positive* - FP) sind zuletzt also jene Instanzen des Datensatzes in denen die Klassifikation jeweils nicht mit der *Ground Truth* übereinstimmt. Diese vier Größen bilden auch die essenziellen Bestandteile einer Konfusionsmatrix (s. Abb. 2.7). Eine solche Konfusionsmatrix ermöglicht es einen schnellen Überblick über die Performance eines Klassifikationsmodells zu bekommen.

Ground Truth	Negativ	70	30
	Positiv	11	89
		Negativ	Positiv
		Klassifikation	

Abbildung 2.7: Beispiel einer Konfusionsmatrix für einen Testdatensatz mit insgesamt 200 Instanzen.

Mit den gerade beschriebenen Größen kann nun die Accuracy berechnet werden. Sie gibt den prozentualen Anteil an richtigen Klassifikationen des Modells an:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

Zwei weitere wichtige Metriken sind die Sensitivität und Falsch-Positiv Rate (*false-positive-rate* - FPR):

$$TPR = \frac{TP}{TP + FN} \quad (2.2)$$

$$FPR = \frac{FP}{FP + TN} \quad (2.3)$$

Diese beiden Größen bilden auch die Grundlage für eine sogenannte Grenzwertoptimierungskurve (*Receiver operating characteristic* - ROC). Hierbei werden beide Größen für unterschiedliche Klassifikationsschwellwerte des Modelles berechnet und gegeneinander aufgetragen (s. Abb. 2.8). Die Performance eines Klassifikators ist umso besser je größer die Fläche unter seiner ROC-Kurve ist (*Area-under-curve* - AUC). Dies bedeutet, dass die FPR minimiert und die TPR maximiert wird.

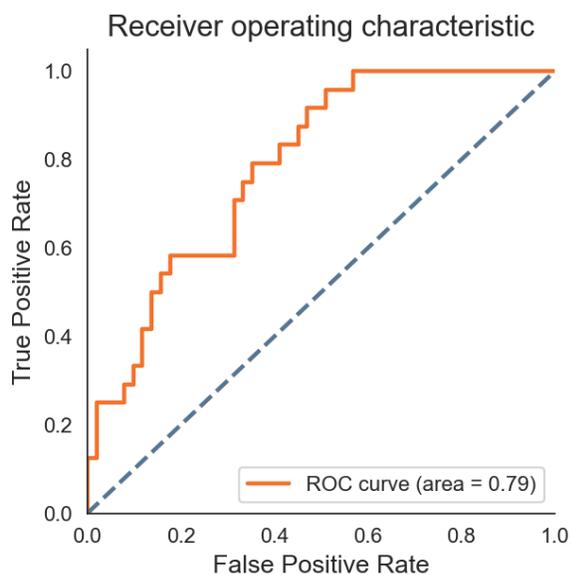


Abbildung 2.8: Beispiel für eine Grenzwertoptimierungskurve. Hierbei wird die Wahr-Positiv Rate (Sensitivität) gegen die Falsch-Positiv Rate (Spezifität) für unterschiedliche Klassifikationsschwellwerte eines Klassifiziers aufgetragen.

2.5.4 Feature Importance Analyse

Je komplexer ein Machine Learning Modell ist, desto schwieriger ist die Interpretation des Modelles. Im Gegensatz zu leicht interpretierbaren Machine Learning Modellen, wie Entscheidungsbäumen, linearen Regressionen oder Bayesian Netzwerken, werden komplexere Modelle auch als Black Box Modelle bezeichnet. Hierzu zählen unter Anderem die Modelle aus dem Bereich des Deep Learnings.

In den letzten Jahrzehnten wurden viele Methoden entwickelt, welche darauf abzielen diese Black Box Modelle zu interpretieren. Eine Art einer solchen Analyse die sogenannte Feature Importance Analysis. In dieser Arbeit wurde SHAP (SHapley Additive exPlanations) [Lundberg and Lee, 2017] für die Feature Importance Analyse der erstellten Klassifikationsmodelle verwendet. SHAP bietet den großen Vorteil, dass es nicht nur die Feature Importance für einen kompletten Datensatz berechnen kann, sondern auch den Beitrag eines jeden Features für eine einzelne Klassifikation. Wie der Name bereits andeutet bilden Shapley Werte die Grundlage für SHAP. Shapley Werte sind eine Methode aus der kooperativen Spieltheorie [Shapley, 1997]. Mithilfe von SHAP Werten lässt sich der Beitrag einer jeden Spieler:in in einem kooperativen Spiel bestimmen. Außerdem lässt sich ermitteln, welchen Gewinn jede einzelne Spieler:in erwarten kann. SHAP liegt die grundlegende Idee zu Grunde, dass die einzelnen Features eines Klassifikationsmodelles die Spieler:innen in einem solchen kooperativen Spiel sind. Mithilfe von SHAP und entsprechend den Shapley Werten lässt sich nun der Beitrag beziehungsweise die Wichtigkeit ϕ_j eines einzelnen Features für eine Instanz des Datensatzes und des entsprechenden Modelloutputs bestimmen. Der Shapley Wert eines Features j kann wie folgt berechnet werden [Štrumbelj and Kononenko, 2014]:

$$\hat{\phi}_j = \frac{1}{M} \sum_{m=1}^M (\hat{f}(x_{+j}) - \hat{f}(x_{-j})) \quad (2.4)$$

Hierbei wird die mittlere Differenz zwischen dem Modeloutput $f(x_{+j})$ und dem Modeloutput $f(x_{-j})$ berechnet. x_{+j} entspricht dem Modellinput mit zufälligen Featurewerten für alle Feature außer Feature j . In x_{-j} sind die Featurewerte des Features j auch zufällig. Diese Differenz wird M mal berechnet und anschließend gemittelt.

Oft wird die globale Wichtigkeit I_j eines Features j berechnet:

$$I_j = \frac{1}{n} \sum_{i=1}^n |\phi_j^{(i)}| \quad (2.5)$$

wobei $|\phi_j^{(i)}|$ der Shapley Wert des Features j und Instanz i des Datensatzes der Größe n ist.

SHAP Werte werden meist mithilfe von zwei verschiedenen Abbildungen dargestellt. Die simpelste Variante der Visualisierung ist ein einfacher Barplot, welcher den durchschnittlichen, absoluten SHAP Wert für jedes einzelne Feature des Modells darstellt (s. Abb. 2.9). Je größer der globale SHAP Wert, desto mehr trägt das entsprechende Feature zur Klassifikation des Modells bei.

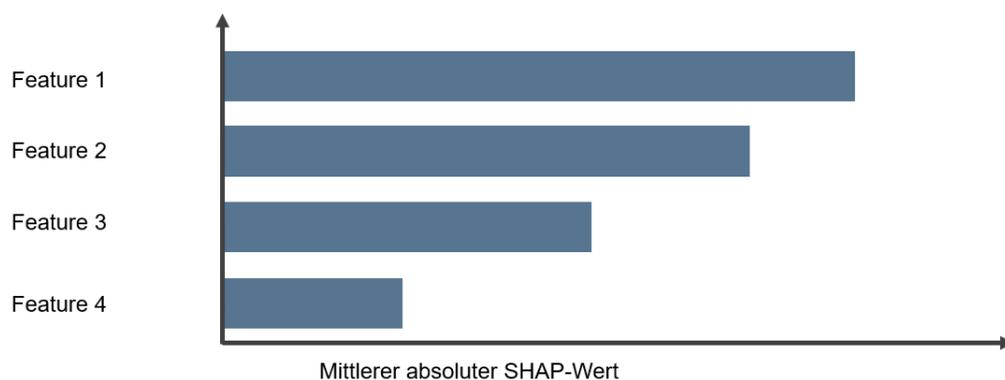


Abbildung 2.9: Beispiel für die Visualisierung von SHAP-Werten mithilfe einer Balkendiagramms Abbildung. Gezeigt sind die mittleren, absoluten SHAP Werte für ein Klassifikationsmodelle. Feature 1 hat in diesem Modell den größten Einfluss auf die korrekte Klassifikation des Modells.

Eine weitere wichtige Visualisierung der SHAP Werte ist die sogenannte Beeswarm Abbildung. Hierbei werden die SHAP Werte jedes Features für eine Menge an Instanzen des Datensatzes aufgetragen. Die so aufgetragenen Punkte werden in der

Regel entsprechend ihrer normalisierten Featurewerten farbkodiert (s. Abb. 2.10). Diese Visualisierung ermöglicht eine Einschätzung, nicht nur über den Beitrag eines jeden Features zu einer Prädiktion (SHAP Wert), sondern auch, wie der Wert eines bestimmten Features sich auf den SHAP Wert auswirkt. In Abbildung 2.10 sind die SHAP Werte für ein hypothetisches Klassifikationsmodell dargestellt. Es lässt sich erkennen, dass hohe Werte des Features 1 sehr wichtig für die korrekte Klassifikation der positiven Klasse sind (hohe SHAP Werte). Entsprechend deuten die niedrigen, negativen SHAP Werte für Feature 1 darauf hin, dass kleine Werte stark zur Klassifikation von der negativen Klasse beitragen.

Entsprechend sind hohe Werte des Features 2 für die Klassifikation der negativen Klasse relevant. Feature 4 hat generell niedrige SHAP-Werte unabhängig vom Featurewert. Dies deutet darauf hin, dass das Klassifikationsmodell dieses Feature nicht für eine Klassifikation nutzt.

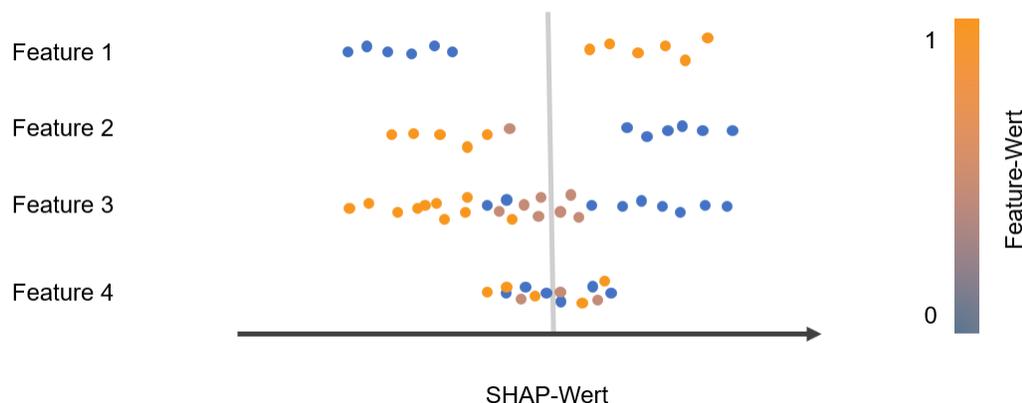


Abbildung 2.10: Beispiel für die Visualisierung von SHAP Werten mithilfe einer Beeswarm Abbildung. Wie auch in Abbildung 2.9 sind die SHAP-Werte für ein hypothetisches Klassifikationsmodell dargestellt.

2.5.5 Bayessche Netze

Ein Modell des maschinellen Lernens, welches in dieser Arbeit verwendet wird, ist das sogenannte Bayessche Netz. Für diese Arbeit wurde nur mit diskreten Zufalls-

variablen gearbeitet, weshalb sich auch die folgende Einführung nur auf diskrete Zufallsvariablen bezieht. Bei einem Bayesschen Netz handelt es sich um ein probabilistisches, graphisches Modell [Stephenson, 2000]. Es stellt die multivariate Wahrscheinlichkeitsverteilung einer Menge von Variablen und ihre Abhängigkeiten untereinander mithilfe eines gerichteten azyklischen Graphen dar (DAG). Ein gerichteter azyklischer Graph besteht aus Knoten und Kanten und darf keine Zyklen enthalten. In einem gerichteten Graph deutet eine Kante in eine bestimmte Richtung. In einem Bayesschen Netz werden die Variablen als Knoten und ihre Abhängigkeiten als Kanten dargestellt. Eine solche multivariate Wahrscheinlichkeitsverteilung ist definiert als [Stephenson, 2000]:

$$P(\mathbf{X}) = \prod_{i=1}^n P(X_i | \text{parents}(X_i)) \quad (2.6)$$

Wobei $P(X_i | \text{parents}(X_i))$ eine sogenannte bedingte Wahrscheinlichkeit darstellt. Die bedingte Wahrscheinlichkeit (z.B. $P(A|B)$) lässt sich mathematisch mittels des Satz von Bayes berechnen. Hierbei wird die Wahrscheinlichkeit für das Eintreten eines Ereignisses A unter der Bedingung berechnet, dass der Zustand eines Ereignisses B bekannt ist:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.7)$$

In Abbildung 2.11 ist ein Bayessches Netz für eine vereinfachte Variante des in [Pearl, 2011] dargestellten Sprinklerproblems, dargestellt. Es besitzt die Knoten *Sprinkler*, *Rain* und *GrassWet*, sowie die Kanten $(\text{Rain}, \text{Sprinkler})$, $(\text{Sprinkler}, \text{GrassWet})$, $(\text{Rain}, \text{GrassWet})$. Jeder Knoten besitzt die zwei Zustände *True* (*T*) und *False* (*F*). Somit repräsentiert das Bayessche Netz die Wahrscheinlichkeitsverteilung der Variablen wie folgt:

$$P(G, S, R) = P(G|S, R)P(S|R)P(R) \quad (2.8)$$

Mithilfe der Formeln 2.7 und 2.6 können nun die bedingten Wahrscheinlichkeiten für alle Variablen im Modell berechnet werden. So kann zum Beispiel die Wahrschein-

lichkeit ($P(R = T|G = T)$) berechnet werden. Hierbei wird also die Wahrscheinlichkeit berechnet, dass es regnet ($Rain = True$) gegeben, dass das Gras nass ist ($Grass\ wet = True$). Dieses Vorgehen wird auch als Inferenz bezeichnet.

$$P(R = T|G = T) = \frac{P(G = T, R = T)}{P(G = T)} = \frac{\sum_{x \in T, F} P(G = T, S = x, T = T)}{\sum_{x, y \in T, F} P(G = T, S = x, R = y)} \quad (2.9)$$

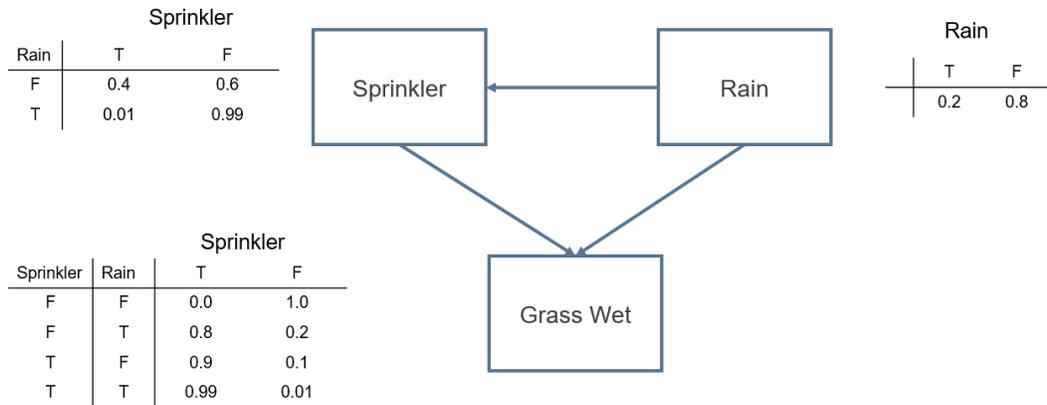


Abbildung 2.11: Bayessches Netz für das Sprinkler Problem (nach [Pearl, 2011]). Das Bayes Netz besteht aus drei Variablen/Knoten *Rain*, *Sprinkler*, *GrassWet*), wobei ihre Abhängigkeiten mithilfe von Kanten im Graphen dargestellt sind.

Mithilfe solcher Inferenzen kann ein Bayessches Netz auch als Klassifikationsmodell genutzt werden. Hierbei legt man einen Schwellwert fest, um die berechnete Wahrscheinlichkeit $P(R = T|G = T)$ entsprechend in $R = T$ zu überführen. Gängigerweise wird ein Schwellwert von 0.5 verwendet. Ist $P(R = T|G = T) \geq 0.5$ kann man annehmen, dass es regnet. Dieser Schwellwert kann mithilfe einer ROC Analyse optimiert werden.

Bisher wurden nur Bayessche Netze mit diskreten Zufallsvariablen beschrieben. Die Modellierung von n Variablen in einem klassischen Bayesschen Netz erfordert die Diskretisierung ebensolcher. Hierbei stehen mehrere gängige Diskretisierungsverfahren

zur Verfügung. Beispiele hierfür sind intervallbasierte-, quantilbasierte- und clusterbasierte Diskretisierungsverfahren.

Zudem gibt es Erweiterungen beziehungsweise alternative graphische Modelle, welche die Modellierung von kontinuierlichen (z.B. *Gaussian Networks*) oder einer Mischung aus diskreten und kontinuierlichen Variablen (*Hybrid Bayesian Networks*) ermöglicht. Eine weitere populäre Erweiterung des Bayesschen Netzes sind dynamische Bayessche Netze (DBN). Im Gegensatz zu statischen Bayesschen Netzen können DBN zeitliche Dynamik modellieren. Hierfür werden dem Netzwerk weitere Zeitscheiben hinzugefügt, sodass mithilfe von zusätzlichen Kanten die zeitlichen Abhängigkeiten der Zufallsvariablen abgebildet werden können.

2.5.6 Künstliche neuronale Netze

Künstliche neuronale Netze (KNN) sind Modelle aus dem Bereich des überwachten maschinellen Lernens. Beim überwachten Lernen werden die Parameter θ eines Modelles so optimiert, dass der Fehler zwischen dem Output des Modelles $f(\mathbf{x}; \theta)$ und einer Zielfunktion $f^*(\mathbf{x})$ minimiert wird.

KNNs besitzen in der Regel eine Kettenstruktur, welche mehrere Funktionen $f^{(1)}$, $f^{(2)}$, ... $f^{(i)}$ in der Form $f(\mathbf{x}) = f^{(i)}(\dots(f^{(2)}(f^{(1)}(\mathbf{x})))\dots)$ verknüpft [Chollet, 2021]. Jede dieser Funktionen $f^{(i)}$ wird als Schicht (*layer*) des Netzwerks bezeichnet, wobei die i -te Schicht die sogenannte Outputschicht (*output layer*) ist (s. Abb. 2.12). i gibt die Anzahl der Layer und somit die Tiefe des KNNs an. Die Weite des KNN wird durch die Dimensionalität der einzelnen Layer bestimmt. Die Dimensionalität jedes Layers wird durch die Anzahl an Einheiten im selbigen beschrieben. Im historischen Kontext des maschinellen Lernens wurden diese Einheiten als künstliche Neuronen bezeichnet, um die Analogie zu biologischen neuronalen Netzen zu verdeutlichen.

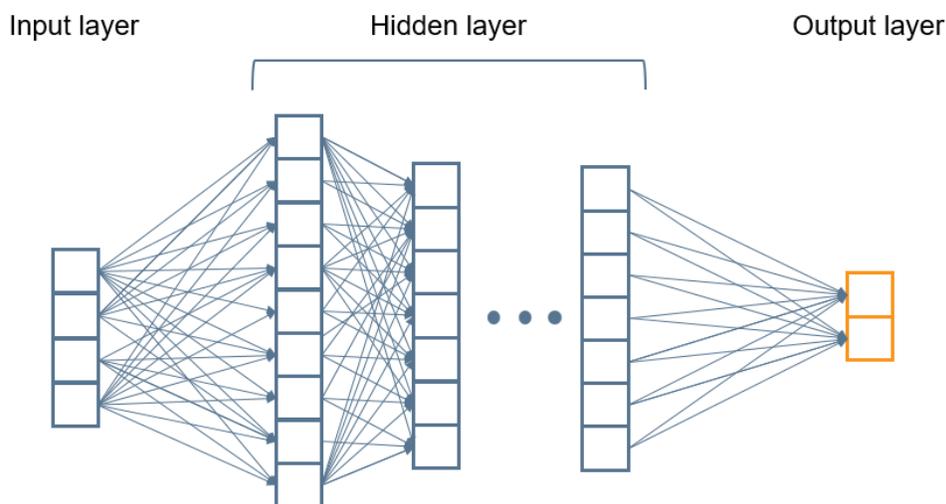


Abbildung 2.12: Schematische Darstellung eines KNN [Commons, 2021]

Jedes Neuron in einer Schicht repräsentiert eine sogenannte Aktivierungsfunktion. Eine häufig verwendete Aktivierungsfunktion ist die sogenannte RELU (*rectified linear unit*). Hierbei handelt sich, um eine Aktivierungsfunktion welche im Bereich $]-\infty, 0]$ einen Wert von null ausgibt. Im Bereich $]0, +\infty[$ verhält sich RELU wie eine lineare Funktion $y(x) = x$. Mathematisch lässt sie sich folgendermaßen beschreiben:

$$\text{ReLU}(x) \hat{=} \max(0, x) \quad (2.10)$$

KNNs müssen, wie alle anderen Machine Learning Modelle trainiert werden. Eines der gängigsten Optimierungsverfahren hierfür ist das Gradientenabstiegsverfahren (*gradient descent*) [Hastie et al., 2009]. Beim Gradientenabstiegsverfahren werden die Parameter x einer Funktion so optimiert, dass die Fehlerfunktion $L(x)$ näherungsweise minimal ist. Die Parameter werden iterativ angepasst, sodass der Wert von $L(x)$ sich entlang des Gradienten der Fehlerfunktion bis zur Konvergenz in ein Minimum verringert. Die Fehlerfunktion kann mehrere Minima besitzen. Somit kann es passieren, dass das Training zur Konvergenz in einem lokalen anstatt dem globalen Minimum führt (s. Abb. 2.13).

In Abschnitt 2.5.1 wurde bereits kurz das Thema Regularisierung und Overfitting angesprochen. [Srivastava et al., 2014] hat 2014 eine Methode namens Dropout für KNN präsentiert. Grundsätzlich ist die Idee, dass bei jedem Trainingsschritt eine zufällige, prozentuale Anzahl ϕ an Neuronen im KNN entfernt werden. Die Gewichte der verbleibenden Neuronen werden mit einem Faktor von $1/(1 - \phi)$ hochskaliert [Hastie et al., 2009].

In den letzten Jahrzehnten wurden viele weitere Varianten von KNNs vorgestellt. So werden beispielsweise *Convolutional Neural Networks* besonders häufig im Bereich der Computer Vision und Bilderkennung verwendet. Rekurrente neuronale Netze, wie die *Long Short-Term Memory* Netze [Hochreiter and Schmidhuber, 1997] werden für die Klassifikation von Zeitreihen oder dem *Natural Language Processing* angewendet.

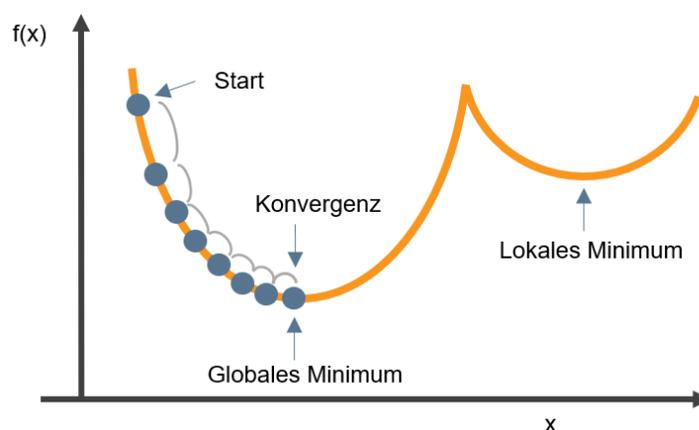


Abbildung 2.13: Beim Gradientenabstiegsverfahren werden die Parameter x einer Funktion so optimiert, dass die Kostenfunktion $f(x)$ minimal ist. Die Parameter werden iterativ angepasst, sodass der Wert von $f(x)$ sich weiter entlang des Gradienten der Kostenfunktion bis zur Konvergenz in ein Minimum verringert. Bei der Optimierung kann es passieren, dass das Modell nicht in das gewünschte globale Minimum konvergiert, sondern in ein lokales Minimum.

Kapitel 3

Klassifikation von Abbiegeintention

3.1 Einführung

Abbiegen durch entgegenkommenden Verkehr kann zu sicherheitskritischen Situationen führen [Hamed et al., 1997, Harding et al., 2014, Yan et al., 2007] und trägt zu 7.4% aller leichten Unfällen [Harding et al., 2014] bei. Menschliche Fehler, insbesondere das falsche Einschätzen der Lückengröße [Plavšić et al., 2010], sind mit die häufigsten Gründe für diese Unfälle. Generell beeinflussen viele Faktoren das Abbiegeverhalten einer Fahrer:in. Zu diesen Faktoren zählen unter Anderem die Lückengröße, die Wartezeit an der Kreuzung [Hamed et al., 1997], aber auch demographische Faktoren, wie das Alter oder Geschlecht der Fahrer:in [Yan et al., 2007]. Wenn die Abbiegeintention einer Fahrer:in in solch einer sicherheitskritischen Situation rechtzeitig erkannt wird, könnte ein Fahrassistenzsystem eventuell das Risiko für einen Unfall verringern. Solche Intentionerkennungsmodelle können die Fahrer:in vor oder während einem gefährlichen Manöver warnen und so das Risiko reduzieren. Mit der Entwicklung und Einführung von Fahrzeug-zu-Fahrzeug (V2V) und Fahrzeug-zu-Infrastruktur Technologie [Harding et al., 2014] können die Ergebnisse einer Intentionserkennung auch genutzt werden, um andere Verkehrsteilnehmer:innen zu warnen

oder eine Intervention im anderen Fahrzeugen zu initiieren. Beispielsweise kann die Fahrer:in des entgegenkommenden Autos mithilfe eines grafischen oder auditorischen Signal gewarnt werden. Alternativ kann das entgegenkommende Fahrzeug bremsen, um die Lücke zu vergrößern und somit die Wahrscheinlichkeit für einen Unfall zu reduzieren [Damm et al., 2019]. Insgesamt schätzt die US National Highway Traffic Safety Administration (NHTSA), dass die V2V Technologie jährlich zwischen 49 und 1083 Leben retten und bis zu 270 000 Verletzungen vermeiden könnte [Harding et al., 2014].

In der Vergangenheit haben bereits einige Wissenschaftler:innen das Abbiegeverhalten an Kreuzungen untersucht, um die Intention der Fahrer:innen und ihren Entscheidungsprozess besser zu verstehen. Hierbei wurden insbesondere kontextuelle Informationen, wie die Lückengröße und Wartezeit betrachtet. [Ragland et al., 2005] haben, basierend auf Videoaufzeichnungen des US Straßenverkehrs, die Lückenakzeptanzstatistik für Abbiegemanöver an Kreuzungen identifiziert. Die Forscher:innen haben ein logistisches Modell verwendet um die Lückenakzeptanzwahrscheinlichkeit zu bestimmen. Die Lückengröße ist jedoch nicht der einzige Faktor, welcher die Abbiegeentscheidung an Kreuzungen beeinflusst. [Hamed et al., 1997] entwickelte ein Regressionsmodell, um die mittlere, kritische Lückengröße für Abbiegemanöver vorherzusagen. Basierend auf Videoaufnahmen und Interviews mit Fahrer:innen an 15 verschiedenen Kreuzungen, fanden die Forscher:innen heraus, dass zusätzlich zur Wartezeit an der Kreuzung [Fricker et al., 1991, Zohdy et al., 2010], auch die Tageszeit und der Anlass für die Fahrt einen Einfluss auf die Lückengröße haben kann. [Zohdy et al., 2010] untersuchten verschiedene Faktoren, wie die Lückengröße, Wartezeit an der Kreuzung, Wetter und die gesamte Reisezeit als unabhängige Variablen für den Abbiegeentscheidungsprozess in einem Abbiegeszenario. Die Autor:innen schlussfolgerten, dass Fahrer:innen mit längerer Wartezeit ungeduldiger wurden und kleinere Lückengrößen beim Abbiegen akzeptieren. Eine Fahrsimulatorstudie von [Yan et al., 2007] zeigte, dass weitere Faktoren, wie das Geschlecht und Alter zusätzlich einen Einfluss auf die Lückenakzeptanz bei Abbiegemanövern hat.

[Liu and Ozguner, 2007] stellen ein allgemeines Fahrermodell für Kreuzungen vor, welches ein dediziertes Entscheidungsmodul für Abbiegevorgänge enthält. Dieses simuliert den Entscheidungsprozess beim Abbiegeprozess an Kreuzungen. [De Beau-

corps et al., 2017] führte eine Fahrstudie durch, um Fahrdaten für Kreuzungen und Kreisverkehre zu erheben. Diese Daten wurden anschließend verwendet um ein menschenähnliches Entscheidungsmodell für diese Verkehrssituationen zu entwickeln. [Damm et al., 2019] präsentiert einen Proof-of-concept, wie die Kombination aus Nutzerzustandserkennung und Nutzerintentionserkennung zu einem substantiellen Anstieg der Sicherheit führen kann. In den letzten zwei Jahrzehnten haben viele Wissenschaftler:innen Modelle aus dem Bereich des maschinellen Lernens verwendet, um die Intention einer Fahrer:in zu erkennen oder vorherzusagen. [Klingelschmitt et al., 2014] verwendeten Bayessche Netze um vier verschiedene Intentionen zu erkennen, wobei hierfür sowohl Informationen über das Fahrverhalten als auch Kontextinformationen über die aktuelle Verkehrssituation genutzt wurde. Das Modell kann vorhersagen, ob das Fahrzeug geradeaus fahren, stoppen oder abbiegen würde. Die Autor:innen fanden heraus, dass die voraussichtliche Geschwindigkeit an der Haltelinie der Kreuzung einer der besten Indikatoren für die Vorhersage der Intention ist. [Phillips et al., 2017] verwendete ein Long Short-Term Memory Netzwerk um vorherzusagen ob eine Fahrer:in an einer Kreuzung abbiegen oder geradeaus fahren wird. Das Modell verwendet verschiedene Fahrdynamikparameter, wie die Geschwindigkeit und Beschleunigung, aber auch Kontextinformationen über das Layout der Kreuzung. Das Modell kann die Intention der Fahrer:in mit einer Accuracy von 85% vorhersagen. [Zhang and Fu, 2020] verwendeten einen hybriden Ansatz um die Abbiegeintention an Kreuzungen zu modellieren. Die Forscher:innen schätzen erst die Fahrdynamikparameter des Fahrzeuges mithilfe eines ARIMA Modelles und prädizierten anschließend ob die Fahrer:in abbiegen oder gerade ausfahren würde mithilfe eines Long Short-Term Memory Netzwerks. Die optimale Erkennungsrate des Modelles lag bei 94.20% und wurde eine Sekunde vor dem Manöver erreicht.

Um solche Modelle zur Klassifikation weiter zu verbessern kann es helfen, weitere Sensoren und Datenquellen zu verwenden. So bieten insbesondere neurophysiologische Messverfahren, wie fNIRS, die Grundlage, um portable Fahrassistenzsysteme, welche die Intention der Fahrer:in bestimmen, zu entwickeln. Hiermit können die Prozesse im Gehirn der Fahrer:in während Entscheidungsaufgaben, wie zum Beispiel das Abbiegen an Kreuzungen, untersucht werden. [Zhu et al., 2019] haben eine Fahrstudie mit simultaner fNIRS Messung durchgeführt. Anschließend wurden

sieben verschiedene Klassifikationsmodelle zur Bremsintention trainiert und verglichen. Die Autor:innen schlussfolgerten, dass ein kombiniertes Modell bestehend aus mehreren Klassifizierern die beste Accuracy mit 90% liefert. [Lin et al., 2018] verwendeten Lineare Diskriminanzanalyse um Abbiegemanöver mithilfe von Elektroenzephalographie zu erkennen. Die Forscher:innen verglichen verschiedene Längen des verwendeten Zeitfensters, wobei das beste Modell eine Accuracy von 70.25% erreichte. Zum jetzigen Zeitpunkt ist dem Autor dieser Arbeit keine Studie bekannt, welche sowohl Kontext- als auch Neuroimaging Daten in ein integriertes Intentionserkennungsmodell vereint.

Im Folgenden werden zwei Modellierungsansätze für ein solches Abbiegeintentionsmodell präsentiert. Hierbei wurde zuerst eine Fahrsimualtorstudie durchgeführt, um die Abbiegeentscheidungen an Kreuzungen zu erfassen. Es wurden Kreuzungen mit Stoppschildern simuliert, in denen die Proband:innen durch den entgegenkommenden Verkehr links abbiegen mussten. Während des Experiments wurde die Hirnaktivität der Proband:innen mit einem fNIRS System 2.3 aufgezeichnet. Die so erhobenen Daten wurden anschließend genutzt, um zwei Nutzerintentionsmodelle für die Klassifikation von Abbiegeintentionen zu trainieren. Eine Feature Importance Analyse wurde außerdem durchgeführt, um den Einfluss der verwendeten Faktoren im Modell zu ermitteln. Generell wurde die Frage untersucht inwieweit die Integration von Daten aus verschiedenen Quellen, wie nutzerspezifische Informationen oder neurophysiologischen Messung, die Performance der Modelle verbessern kann.

3.2 Material & Methoden

Dreizehn Proband:innen (7 weiblich, 54%, mittleres Alter \pm SD = 23.8 Jahre \pm 2.61) nahmen an einer Fahrsimulatorstudie teil. Alle Proband:innen besaßen einen deutschen Führerschein und erhielten eine monetäre Belohnung für die Studienteilnahme. Das Experiment wurde im Fahrsimulator der Carl-von-Ossietzky Universität durchgeführt (s. 2.4).

Während des Experimentes wurde die Hirnaktivität der Proband:innen mithilfe eines fNIRS Systems gemessen. Das verwendete System misst die relativen Konzentrati-

onsunterschiede von oxygeniertem Hämoglobin (HbO) und reduziertem Hämoglobin (HbR). Das fNIRS System besitzt 32 optischen Sensoren, welche insgesamt 107 Kanäle haben. Die Hirnaktivität kann mit einer Frequenz von 1.955 Hz gemessen werden und ist mithilfe einer USB Schnittstelle mit dem Fahrsimulator beziehungsweise der Fahrsimulationssoftware synchronisiert.

Während des Experiments sollten die Proband:innen mehrere Abbiegemanöver an städtischen Kreuzungen mit entgegenkommendem Verkehr (POV, Principal Other Vehicle) durchführen. Die entgegenkommenden Fahrzeuge fahren mit einer Geschwindigkeit von 50 km/h. An jeder Kreuzung stand ein Stopp-Schild an dem die Proband:Innen halten mussten (s. Abb. 3.1). Die Kreuzungen des Verkehrsszenarios sind y-förmig aufgebaut. Dies erleichtert das Abschätzen der Lückengrößen zwischen den entgegenkommenden Fahrzeugen.

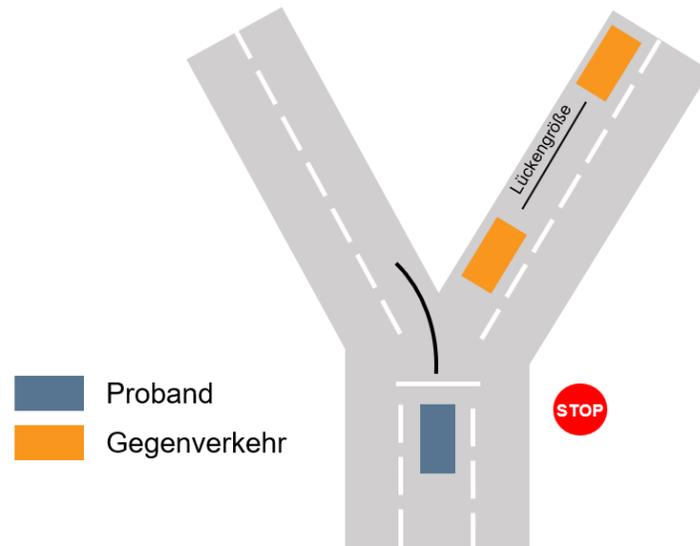


Abbildung 3.1: Skizze der Kreuzung für das durchgeführte Abbiegemanöver.

Der entgegenkommende Verkehr bestand aus Lückengrößen zwischen 1s und 6s, was wiederum 13.9m und 83.4m entspricht. Die Verteilung der Lückengrößen wurde entsprechend der Ergebnisse aus [Ragland et al., 2005] konstruiert. Die Forscher:innen haben hier die Lückenverteilungen in fünf verschiedenen Kreuzungen

erhoben, wobei eine Lückegröße von 4s am häufigsten beobachtet wurde. Die niedrigsten Lücken Größen waren etwa 2s. Insgesamt wurden in diesem Experiment acht bis zehn entgegenkommende Fahrzeuge in einer Kreuzungssituation simuliert. Nach dem zehnten Fahrzeug erschien kein weiteres mehr.

Um sich an den Fahrsimulator zu gewöhnen fuhren die Proband:innen eine Trainingsfahrt, welche aus einer kurzen Fahrt auf einer Landstraße und dem Durchfahren von elf Kreuzungen bestand. Der Hauptteil des Experiments dauerte circa 70 Minuten und jede Proband:in durchfuhr insgesamt 100 Abbiegesituationen. Das Experiment wurde in 10 Blocks mit je 10 Kreuzungen aufgeteilt. Nach jedem Block gab es eine kurze Pause von 90 Sekunden. Die Proband:innen hatten ein Zeitlimit, um einen Block abzuschließen. Das Zeitlimit wurde angewendet, um die Proband:innen zum Abbiegen zu motivieren, anstatt an einer Kreuzung zu warten bis alle entgegenkommenden Fahrzeuge die Kreuzung passiert haben. Hierbei erhielten die Proband:innen eine zusätzliche monetäre Belohnung für jeden Block, welchen sie im Zeitlimit absolviert haben. Die Anzahl der durchfahrenen Kreuzungen und die aktuelle Zeit pro Block wurde in einem Head-up Display in der Simulation für die Proband:innen angezeigt. Über den Verlauf der gesamten Studie wurden nur 0.16% aller Abbiegemanöver durchgeführt nachdem alle entgegenkommenden Autos die Kreuzung passiert haben. Die Proband:innen füllten nach dem Experiment einen Fragebogen mit Fragen zu demographischen Informationen und zu ihrem subjektiv wahrgenommenen Fahrstil aus. Die Fragen zu ihrem Fahrstil wurden aus [Taubman-Ben-Ari et al., 2004] entnommen und finden sich auch im Anhang dieser Arbeit wieder (s. 7.3). Basierend auf den Ergebnissen der Fragebögen wurden die mittleren Werte für die Fahrstil kategorien *Wütend*, *Riskant*, *Vorsichtig* und *Ängstlich* berechnet.



Abbildung 3.2: Der verwendete Fahrsimulator der Carl-von-Ossietszky Universität mit einer Probandin. Die Hirnaktivität während des Experimentes wird mithilfe eines fNIRS Systems gemessen.

3.3 Klassifikation von Abbiegeintention mit Bayesschen Netzen

3.3.1 Modellierung

Zuerst wurden Bayessche Netze verwendet, um die Abbiegeintention der Proband:innen zu modellieren (s. Abb. 3.3 und 2.5.1). Mehr als 5000 Abbiegeentscheidungen über alle Proband:innen wurden in der oben beschriebenen Studie erhoben. Alle Variablen wurden intervalbasiert diskretisiert und als diskrete Variablen im Bayesschen Netz modelliert. Aus den Studiendaten wurden die Lückengrößen und die Anzahl der bereits abgewarteten Autos für jede Abbiegeentscheidung für die Modellierung extrahiert. Grund hierfür ist, dass insbesondere die Lückengröße einer der wichtigsten Faktoren beim Entscheidungsprozess des Abbiegens ist [Hamed et al., 1997]. [Hamed et al., 1997] suggeriert außerdem, dass die Wartezeit ein wichtiger Faktor

ist, welcher die Lückenakzeptanz und somit die Abbiegeintention beeinflusst. Aus diesem Grund wurde die Anzahl der bereits abgewarteten Autos in das Modell integriert. Des Weiteren wurden der Fahrstil- und Demographiefragebogen ausgewertet, um dem Modell nutzerspezifische Informationen hinzuzufügen. [Yan et al., 2007] argumentiert, dass sowohl das Alter als auch das Geschlecht einen wichtiger Faktor für den Entscheidungsprozess beim Abbiegen ist. Außerdem wurden die subjektiven Fahrstile aus dem Fragebogen in das Modell integriert. Hierbei wurden Fragen zu ängstlichem, vorsichtigem, riskanten und wütendem Fahrverhalten abgefragt. Die Modellierung wurde in *R* mithilfe des *bnlearn* Paketes durchgeführt. Für die Evaluation des Modelles wurden die Accuracy und die Area-under-curve (AUC) für eine 4-fold Kreuzvalidierung berechnet. Die Trainings- und Testdaten des Modells wurden balanciert, um eine gleiche Verteilung von positiven (*Abbiegen*) und negativen (*Nicht abbiegen*) Instanzen zu haben. Insgesamt besteht der Trainingsdatensatz aus 1500 Instanzen und der Testsatz aus 500 Instanzen.

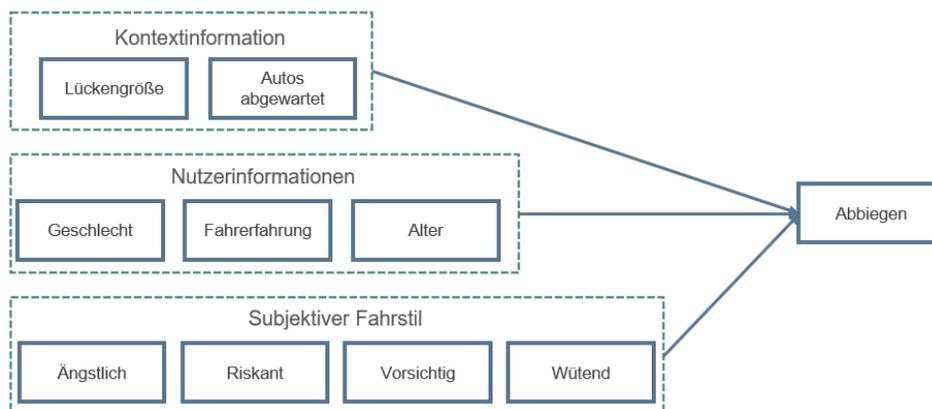


Abbildung 3.3: Struktur des Bayesschen Netzes mit den zehn verwendeten diskreten Variablen.

3.3.2 Ergebnisse

Die Auswertung zeigt, dass das Modell die Abbiegeintention der Proband:innen mit einer Accuracy von 74.00% klassifizieren kann. Da der Datensatz im Bezug auf die

Verteilung der Klassen balanciert wurde ist die Baseline der Accuracy für ein binäres Klassifikationsmodell 50.00%, womit das präsentierte Modell deutlich über dieser Baseline liegt. Die ROC Kurve des Modells ist in Abbildung 3.4 dargestellt. Die AUC des Modells liegt bei 0.81 und somit weit über der eines uninformierten Klassifikators (0.50).

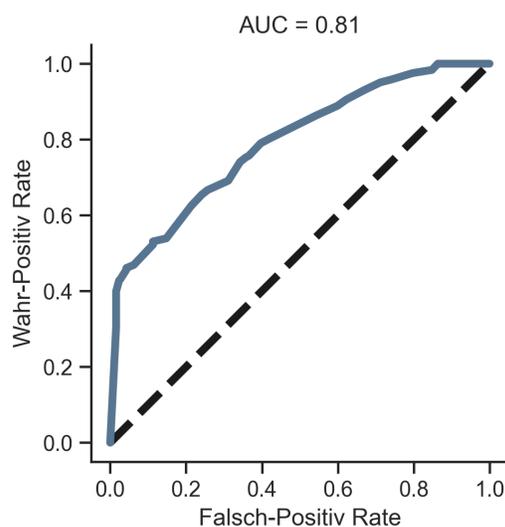


Abbildung 3.4: Receiver-operating-characteristics Kurve für das Modell. Das Modell hat eine AUC von 0.81 und eine Accuracy von 74.00% mit einem Klassifikationsschwellwert von 0.50

Um den Einfluss eines jeden Features im Modell zu ermitteln wurde SHAP verwendet [Lundberg and Lee, 2017]. In Abbildung 3.5 ist eine Beeswarm Visualisierung für die SHAP-Werte jedes Features und Datenpunktes aufgetragen. Wie zu erwarten sind die Lückengröße und Wartezeit die wichtigsten Feature für die Klassifikation der Abbiegeintention. Große Lückengrößen (rot) haben einen hohen, positiven SHAP-Wert und tragen somit stark zu der Klassifikation von *Abbiegen* bei. Niedrige Lückengrößen (blau) führen entsprechend eher zu einer Klassifikation von *Nicht abbiegen*. Lange Wartezeiten führen tendenziell eher zur Klassifikation von *Abbiegen*. Die mittleren, absoluten SHAP-Werte (s. Abb. 3.6) haben keinen großen Einfluss

auf den Modelloutput wie die Kontextvariablen (Wartezeit, Lückengröße) sind jedoch trotzdem relevant für viele der Klassifikationen, da ihre SHAP-Werte in Abbildung 3.5 ungleich null sind. Die Tatsache, dass eine Proband:in einen *Wütenden* Fahrstil hat kann zum Beispiel zu einer erhöhten Wahrscheinlichkeit für *Abbiegen* als Modelloutput führen.

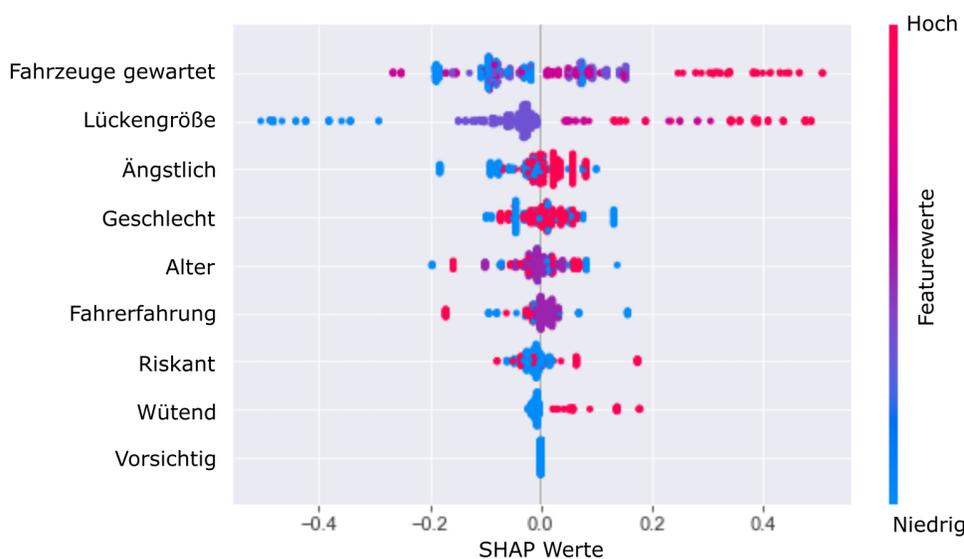


Abbildung 3.5: Beeswarm Abbildung für die SHAP Feature Importance Analyse.

Abbildung 3.6 zeigt die mittleren, absoluten SHAP-Werte für alle Feature. Jedes Feature, außer der *Vorsichtige* Fahrstil, hatten einen Einfluss auf die Vorhersage des Modells. Nutzerspezifische Feature haben einen SHAP-Wert im Bereich 0.02 und 0.03, wobei die Lückengröße einen mittleren absoluten SHAP-Wert von 0.11 hat. Dies macht sie zu dem wichtigsten Feature für das Modell. Die nutzerspezifischen Feature haben somit einen deutlich niedrigeren, mittleren SHAP-Wert, können jedoch für einzelne Klassifikationen von Instanzen des Datensatzes relevant sein. Da die Inferenz in komplexen Bayesschen Netzen langsam sein kann, ist es wichtig, nur relevante Variablen in einem Bayessche Netz zu verwenden. Die Ergebnisse einer Feature Importance Analyse können genutzt werden, um die Anzahl an Feature in ei-

dem Modell zu reduzieren und so die Inferenzzeit zu verkürzen. Dies ist insbesondere für Anwendungen in Realzeit wichtig.

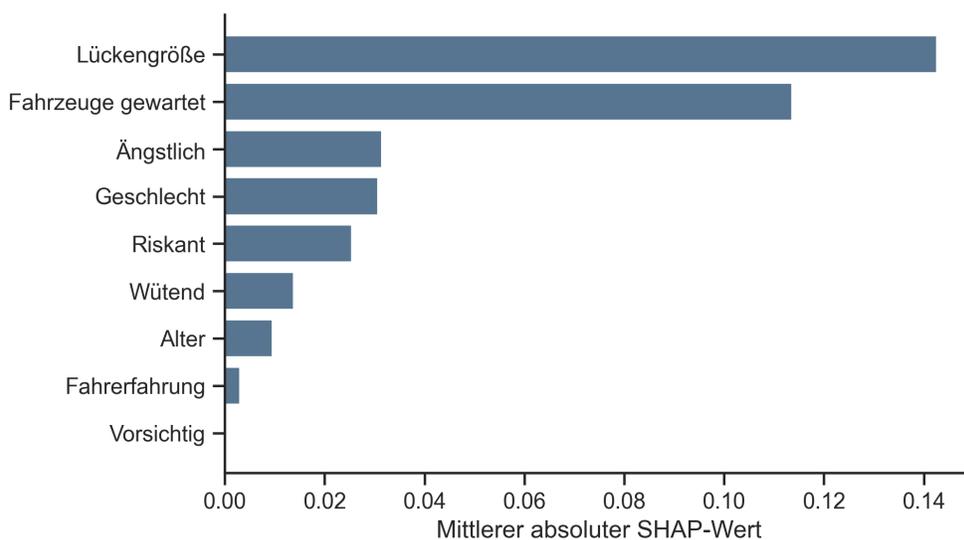


Abbildung 3.6: Übersicht über die absoluten, gemittelten SHAP-Werte für jede Variable im Modell.

3.4 Integriertes Modell zur Klassifikation der Abbiegeintention

Im Folgenden wird ein weiterer Modellierungsansatz zur Abbiegeintentionsklassifikation präsentiert. Hierbei werden die Hirnaktivitätsmessungen der Proband:innen in die Modellierung miteinbezogen. Neuroimaging stellt eine direktere und idealerweise unvoreingenommene Methode zur Messung von Zuständen und Intentionen der Proband:innen dar. Somit sollte ein Intentionserkennungsmodell mit Hirnaktivitätsdaten eine bessere Performance aufweisen.

Hierzu wird zu Beginn die vorgenommenen Schritte zur Datenvorverarbeitung erklärt. Anschließend wird der Modellierungsansatz dargestellt und die entsprechenden Ergebnisse sowohl auf Probanden- als auch Gruppenlevel analysiert und diskutiert.

3.4.1 Datenvorverarbeitung

Die fNIRS Daten wurden von Mitarbeiter:innen der Arbeitsgruppe *Angewandte Neurokognitive Psychologie* mithilfe der nirsLAB Analyse [Xu et al., 2014] vorverarbeitet. Hierbei wurden allen voran systematische Artefakte entfernt. Eine detaillierte Erklärung der fNIRS Datenvorverarbeitung findet sich in [Unni et al., 2022]. Im Mittel konnten Daten von 99 (Standardabweichung = 8.7) fNIRS Kanälen pro Proband:in verwendet werden. Die normalisierten fNIRS Daten wurden entsprechend einer 5-fold Kreuzvalidierung in Trainings- und Testdaten unterteilt. Auf den Trainingsdaten wurde eine Hauptkomponentenanalyse (PCA) durchgeführt, wodurch die Trainingsdaten in eine Menge an linear unkorrelierten Variablen (Principal components - PCs) transformiert wurden. Bei einer PCA werden die PCs so gewählt, dass der erste PC die größte Varianz der Daten abbildet. Alle weiteren PCs bilden jeweils eine absteigende Varianz des Gesamtdatensatzes ab. Die Eigenvektoren der PCA wurden anschließend verwendet um die Testdaten in den PC Raum zu transformieren [Unni et al., 2022]. Des Weiteren wurde der erste PC entfernt, da er oft mit Bewegungsartefakten korreliert [Brigadoi et al., 2014].

Die experimentellen Daten wurden basierend auf zwei Phasen gelabelt: *Abbiegen* und *Nicht Abbiegen*. Beide Phasen bestanden aus einem viersekündigen Zeitfenster (s. 3.7). Die *Abbiegen* Phase wurde als das Intervall vor dem Abbiegevorgang und somit der Planungs- und Entscheidungsphase definiert. Um die hemodynamische Verzögerung des BOLD Signals (Änderung des relativen Verhältnisses von Oxy- und Deoxyhämoglobin) miteinzubeziehen wurde für die fNIRS Analyse das Intervall zwei Sekunden vor dem Drücken des Gaspedals und zwei Sekunden nach Beginn des Abbiegemanövers gewählt. Diese viersekündige Verzögerung schliesst so die Hirnaktivitätsänderungen bezüglich der Motoraktivität während dem Abbiegemanöver aus. Die *Nicht Abbiegen* Phase ist als das viersekündige Zeitfenster vor der *Abbiegen* Phase definiert. In diesem Zeitfenster wartet die Proband:in auf die richtige Lückengröße. Ein Abstand von 0.5 Sekunden wurde gewählt um den Überlapp zwischen den beiden Phasen zu reduzieren.

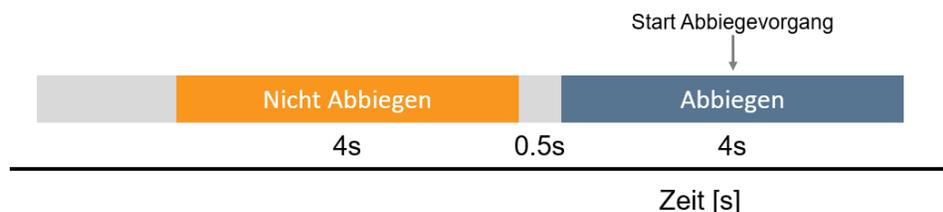


Abbildung 3.7: Schematische Darstellung der fNIRS Datenvorverarbeitung.

3.4.2 Modellierung

Für jede Proband:in wurden drei verschiedene künstliche neuronale Netze (KNNs) trainiert und ausgewertet. Die KNNs unterscheiden sich jeweils in der Art und Anzahl an Inputfeatures. Die KNNs besitzen zwei versteckte Schichten mit jeweils 25 Neuronen. Alle Neurone der versteckten Schichten verwenden die ReLu Aktivierungsfunktion [Hahnloser et al., 2000] und 10% Dropout [Srivastava et al., 2014], um Overfitting zu vermeiden. Die Outputschicht nutzt eine Sigmoid Funktion für die Klassifikation der Abbiegeintention. Die Netzwerke wurden mit dem ADAM Optimierungsverfahren [Kingma and Ba, 2014] für jeweils 500 Epochen trainiert, wobei binäre Kreuzentropie als Fehlerfunktion verwendet wurde. Ein Modell wurde nur auf Kontextfeatures trainiert (Kontextmodell). Hierbei wurde die Lückengröße und die Wartezeit an der Kreuzung verwendet. Das zweite Modell (fNIRS Modell) wurde auf den zweiten bis achten PCs der fNIRS Daten trainiert. Das dritte und letzte Modell (Kombiniertes Modell) nutzt sowohl Kontext wie auch fNIRS Feature. Alle Inputfeature wurden standardisiert, sodass sie einen Mittelwert von null und eine Standardabweichung von eins haben.

Für jede Proband:in und Modell wurden die Accuracys und Konfusionsmatrizen berechnet und eine ROC Analyse durchgeführt. Außerdem wurde eine Feature Importance Analysis (s. 2.5.1) durchgeführt, um den Beitrag jedes Features zum Modelloutput darzustellen. Hierfür wurde SHAP verwendet [Lundberg and Lee, 2017]. SHAP Werte können den Einfluss eines Features und seine entsprechenden Featurewerte

auf den Output eines Modells darstellen. Der mittlere, globale SHAP Wert wurde für jeden Schritt der Kreuzvalidierung und Proband:in und für alle Inputfeature berechnet.

3.4.3 Ergebnisse der Modellierung auf Probandenlevel

Der erste Schritt der Auswertung der Modelle war die Berechnung der Accuracy. Die Resultate finden sich in Abbildung 3.8. Das fNIRS Modell hat eine Median Accuracy von 83.1%. Das Kontextmodell hat eine Median Accuracy von 83.8% und die Median Accuracy des kombinierten Modells liegt bei 91.1%.

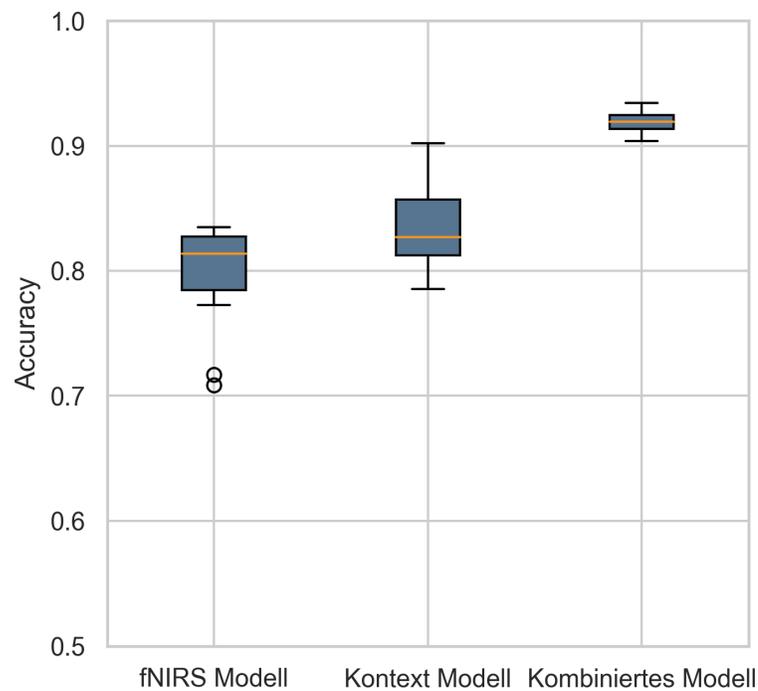


Abbildung 3.8: Boxplot der Accuracys für alle Modelle, Schritte der Kreuzvalidierung und Proband:innen.

Abbildung 3.9 zeigt die durchschnittlichen Konfusionsmatrizen für die drei Modelle. Hierfür wurden die Konfusionsmatrizen für jede Proband:in und Schritt der Kreuzvalidierung berechnet und anschließend gemittelt. Insgesamt können die Modelle eine positive Abbiegeintention mit mindestens 88.8% richtig klassifizieren. Sowohl das fNIRS- als auch das Kontext Modell haben mehr als 24% falsch klassifizierte *Nicht Abbiegen* Instanzen. Falsch-Negative, also falsch klassifizierte *Abbiegen* Instanzen sind die sicherheitskritischsten Instanzen. Sowohl das fNIRS- als auch das Kontextmodell klassifizieren etwa 10% dieser Events falsch und erkennen eine *Nicht Abbiegen* Intention, obwohl die Proband:in die Intention hat abzubiegen. Das kombinierte Modell kann diese Missklassifikationen auf nur 2.5% reduzieren. Abbildung 3.10 zeigt die Receiver-Operating-Characterisitic (ROC) Kurve für alle drei Modelle und einer Kurve pro Proband:in. Die entsprechende, mittlere Area-Under-Curve (AUC) und ihre Standardabweichung sind im Titel dargestellt. Das kombinierte Modell hat die höchste AUC mit einem Wert von 0.94. Das Kontextmodell hat eine etwas niedrigere AUC von 0.92. Es zeigt sich jedoch eine größere Variabilität zwischen den Proband:innen.

Die ROC Kurve für das Kontextmodell hat eine vergleichbare AUC ($AUC = 0.92 \pm 0.04$) wie das kombinierte Modell ($AUC = 0.94 \pm 0.02$). Einige der Kurven des Kontextmodells haben jedoch deutlich kleinere AUCs. Das fNIRS-Modell hat eine durchschnittliche AUC von 0.83 ± 0.06 und somit die höchste Variabilität der drei Modelle.

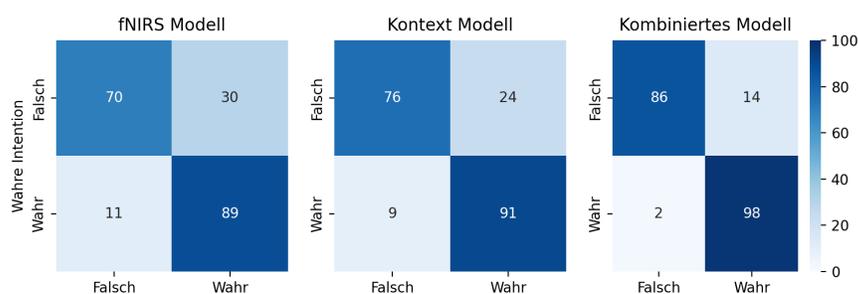


Abbildung 3.9: Konfusionsmatrizen für alle drei Modelle auf Probandenlevel.

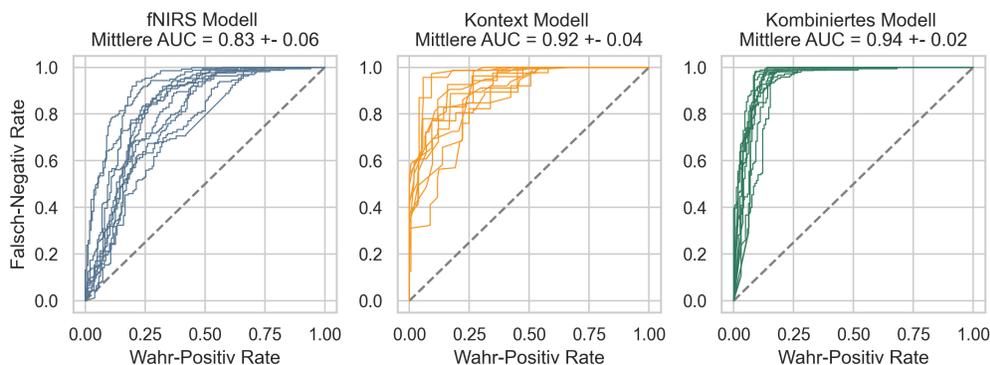


Abbildung 3.10: ROC Kurven aller drei Modelle auf Probandenlevel.

Feature Importance Analysen können verwendet werden um den Beitrag eines Features auf den Modeloutput zu erheben. Wir haben SHAP verwendet, um zu zeigen wieviel die einzelnen Feature des kombinierten Modells zur Abbiegeintentionserkennung beitragen. Der mittlere SHAP Werte für jedes Feature und entsprechend der mittlere Einfluss auf den Modeloutput ist in Abbildung 3.11 dargestellt. Es ist zu erkennen, dass die Lückengröße mit einem SHAP Wert von 0.21 den größten Einfluss auf den Modeloutput hat. Die nächsthöheren SHAP Werte haben die PCs der fNIRS Daten.

Abbildung 3.11 zeigt eine Beeswarm Visualisierung der SHAP Analyse für eine Proband:in und einen Testdatensatz. Jeder Punkt repräsentiert eine Instanz des verwendeten Testdatensatzes. Die Featurewerte einer jeden Instanz sind entsprechend farbkodiert und für die Visualisierung normiert. Man erkennt dass große Lückengrößen und die Anzahl der vorbeigefahrenen Fahrzeuge (rot) einen großen, positiven SHAP Wert haben. Dies suggeriert, dass das Modell eine positive Abbiegeintention bei Instanzen klassifiziert, bei denen große Werte für diese Features vorhanden sind.

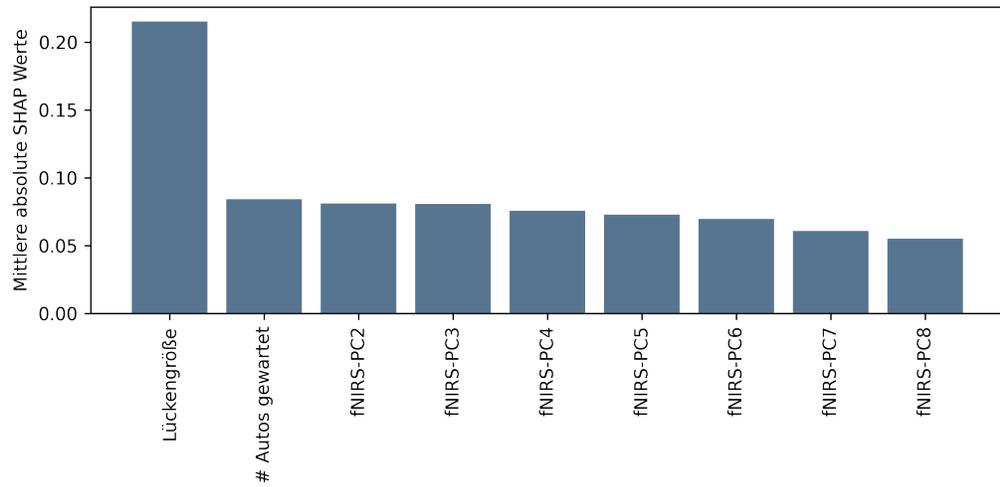


Abbildung 3.11: Absolute, globale SHAP Werte für das kombinierte Modell.

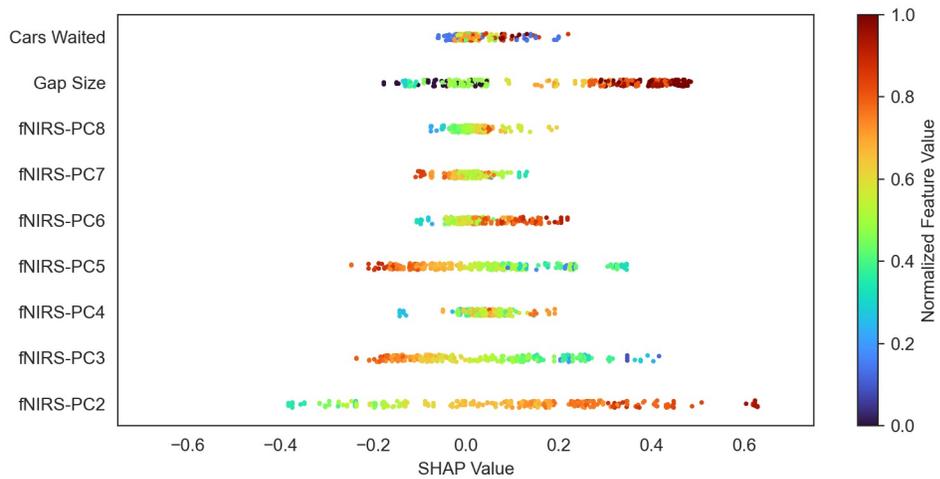


Abbildung 3.12: Beeswarm Abbildung der SHAP Werte für das kombinierte Modell.

3.4.4 Ergebnisse der Modellierung auf Gruppenlevel

Alle drei Modelle wurden auch auf Gruppenlevel trainiert und analysiert. In Abbildung 3.13 finden sich die Konfusionsmatrizen für die drei Modelle gemittelt über die Kreuzvalidierungsdurchgänge. Es zeigt sich, dass sowohl das Kontext- wie auch das kombinierte Modelle eine ähnliche Anzahl an wahr-richtigen und wahr-falschen Klassifikationen hat. Die Ergebnisse der ROC-Analyse finden sich in Abbildung 3.14. Hierbei entspricht jede Linie einem Trainingsdurchlauf mit einer anderen Anzahl an Probandendaten. Die durchgezogene Linie entspricht einem Modell, welches mit Daten von drei Proband:innen trainiert wurde. Es lässt sich erkennen, dass das fNIRS-Modell deutlich niedrigere AUC-Werte hat. Das Kontextmodell und das kombinierte Modell hat ähnliche AUC-Werte. Es lässt sich erkennen, dass sich die AUC-Werte für das fNIRS- und das kombinierte Modell mit zunehmender Anzahl an Probandendaten verringern.

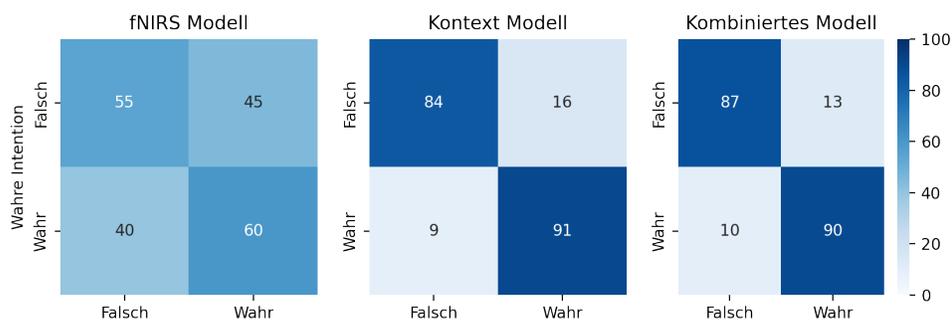


Abbildung 3.13: Konfusionsmatrizen für alle drei Modelle auf Gruppenlevel.

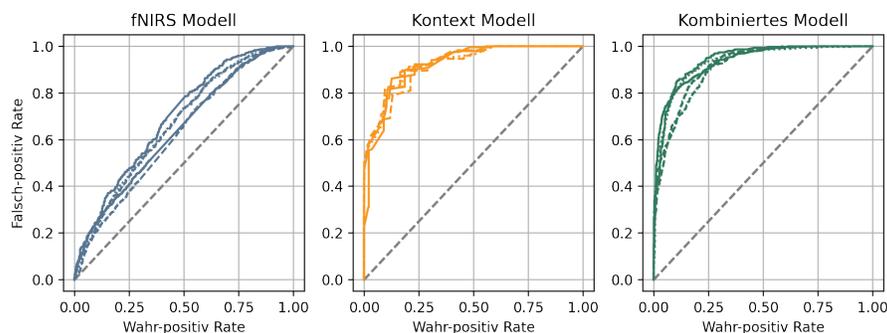


Abbildung 3.14: ROC Kurven aller drei Modelle auf Gruppenlevel.

3.5 Diskussion

In dieser Studie wurden die Ergebnisse einer Fahrstudie vorgestellt und ein Modell zur Klassifikation von Abbiegeintention an Kreuzungen präsentiert. Die Auswertung des Modells zeigt, dass die Abbiegeintention mit einer deutlich höheren Genauigkeit als die theoretische Baseline klassifiziert werden kann. Des Weiteren ist die AUC mit einem Wert von 0.81 deutlich höher als die AUC eines untrainierten Klassifizierers (0.50). Eine falsch-negative Klassifikation würde bedeuten, dass das Modell vorhersagt, dass das SV wartet, wobei die Fahrer:in eigentlich die Intention hat abzubiegen. Diese Vorhersagen eines defensiven und sicheren Verhaltens spiegeln nicht die eigentlich riskante *Ground Truth* wider und sollten von einem sicherheitskritischen Standpunkt so gut es geht vermieden werden. Der Klassifikationsschwellwert sollte entsprechend angepasst werden.

Mithilfe von Feature Importance Analyse konnte gezeigt werden, dass nutzerspezifische Informationen die Klassifikation von Abbiegeintention in unserem Anwendungsfall verbessern konnte. Es sollte jedoch beachtet werden, dass die Proband:innen einer relativ homogenen Demographie entstammen. Die Standardabweichungen von Alter und Fahrerfahrung sowie die der Ergebnisse der Fragebögen waren niedrig. Des Weiteren ist die subjektive Erfassung von Fahrstilen nicht immer akkurat (s. [McKenna et al., 1991]). Außerdem ist ein Stichprobengröße von $N = 13$ sehr gering für die Generalisierung der präsentierten Resultaten.

Nutzerspezifische Informationen können beispielsweise mithilfe eines kurzen Fragebogens nach dem Kauf eines Fahrzeuges erhoben werden, falls die Nutzer:in damit einverstanden ist seine persönlichen Daten für einen hypothetischen Sicherheitsgewinn durch ein Abbiegeintensionsmodell zu teilen. Ähnliche Modelle können und wurden auch für andere Verkehrssituationen und Manöver untersucht. Beispiele hierfür wären das automatische Erkennen von Spurwechsel. Der Output eines solchen Intensionsmodells könnte mithilfe einer Mensch-Maschine-Schnittstelle im entgegenkommenden Fahrzeug dargestellt werden. Hinsichtlich des Fortschritts im Bereich von Fahrerassistenzsystemen und autonomen Fahrzeugen könnte auch eine direktere Intervention getestet werden. Falls das Modell ein gefährliches Abbiegemanöver klassifiziert, könnte das entgegenkommende Fahrzeug automatisch bremsen.

Beim zweiten Modellierungsansatz lag der Fokus auf der Integration von Kontext- und neurophysiologischen Messdaten für die Abbiegeintensionsklassifikation. Die Auswertung der Modelle auf Probandenlevel zeigt, dass eine Modell mit sowohl Kontext-, als auch neurophysiologischen Informationen die Intention einer Fahrer:in deutlich besser klassifizieren kann, als Modelle mit nur Kontext- oder neurophysiologischen Informationen. Besonders in Bezug auf die falsch-negativen Klassifikationen (kein Abbiegen klassifiziert, wenn abgelenkt wird), stellen neurophysiologischen Messdaten eine weitere unabhängige Informationsquelle dar, welche die Anzahl an sicherheitskritischen Situationen reduzieren kann. Unser Abbiegeintensionsmodell mit nur fNIRS Daten erzielt eine Median Accuracy von 83.1%, welches bereits höher ist als die Accuracies, welche in [Lin et al., 2018] präsentiert wurden. Die Median Accuracy von 83.8% unseres Kontextmodells ist etwas niedriger als die Accuracy von 85%, welche in [Phillips et al., 2017] gezeigt wird. Hierzu muss jedoch erwähnt werden, dass sich nicht nur das experimentelle Paradigma zwischen [Phillips et al., 2017] und unserer Studie unterscheidet, sondern dass die Forscher:innen mehr Kontextinformationen, wie zum Beispiel das Layout der Kreuzung, in ihrem Modell verwendet haben. Dies kann wiederum die bessere Performance erklären. Unser kombiniertes Modell erreicht eine Median Accuracy von 91.9%. Dies ist höher als die Ergebnisse präsentiert in [Lin et al., 2018], welche ein ähnliches experimentelles Paradigma untersuchten und Elektroenzephalografie nutzten, um Abbiegemanöver zu klassifizieren. Das Modell, welches in [Zhang and Fu, 2020] präsentiert wurde, erreicht eine

etwas besser Accuracy von 94.2%, wobei hier mehr Kontext und Fahrdynamikinformation als in unserer Studie genutzt wurden.

Die Ergebnisse der ROC Analyse (s. Abbildung 3.10) zeigen, dass das Kontextmodell eine durchschnittliche AUC von 0.92 ± 0.04 und das kombinierte Modell eine AUC von 0.94 ± 0.02 hat. Auch wenn sich die Durchschnittswerte nicht stark unterscheiden ist es wichtig zu betonen, dass das Kontextmodell eine höhere Variabilität zwischen den Proband:innen aufweist. Für manche Proband:innen kann das Kontextmodell vergleichbare Werte zum kombinierten Modell erreichen. Für andere Proband:innen ist die AUC jedoch deutlich schlechter. Wir stellen die Hypothese auf, dass diese Proband:innen in einigen Kreuzungen ein Abbiegeverhalten gezeigt haben, welches nicht einfach mit dem Kontextmodell abbildbar ist. Nachdem das Kontextmodell nur zwei Variablen hat, die Lückengröße und Wartezeit, hat das Modell gelernt, die Abbiegeintention der Fahrer:in basierend auf der Kombination dieser beiden Variablen zu klassifizieren. Dies entspricht einer Kombination aus einer akzeptablen Lückengröße und Wartezeit der Fahrer:in. Das Kontextmodell kann keine richtige Klassifikation machen, wenn die Fahrer:in sich entscheidet eine kleiner Lücke als gewöhnlich zu nehmen oder deutlich länger bzw. kürzer an der Kreuzung zu warten. In diesen Situationen kann das kombinierte Modell Informationen aus der fNIRS Hirnaktivitätsmessung verwenden, um diese untypischen Abbiegeentscheidungen richtig zu klassifizieren. Dies führt wiederum zu einer allgemein konsistenteren Performanz des Modells.

Wir haben eine SHAP-Feature-Importance-Analyse durchgeführt, um den Beitrag der Kontext- und fNIRS-Feature für die Abbiegeintentionserkennung zu verstehen. Unsere Resultate suggerieren, dass die beiden Kontextvariablen Lückengröße und Wartezeit am wichtigsten für den Modelloutput sind. Der mittlere SHAP-Wert für die Lückengröße ist jedoch fast dreimal so hoch wie der SHAP-Wert der Wartezeit. Diese Resultate decken sich mit den Ergebnissen anderer Studien zu Abbiegeentscheidungen, welche suggerieren, dass die Lückengröße die wichtigste Variable im Entscheidungsprozess beim Abbiegen ist [Fricker et al., 1991, Zohdy et al., 2010, Yan et al., 2007, Ragland et al., 2005]. Die SHAP Analyse zeigte außerdem dass die meisten Principal Components der fNIRS Daten einen ähnlich großen Einfluss haben wie die Wartezeit. Eine detaillierte Analyse der SHAP-Werte zeigte, dass das Modell In-

formationen in bestimmten PCs für eine *Abbiegen* und entsprechend *Nicht Abbiegen* Klassifikation nutzen kann (s. Abbildung 3.12). Wie zu erwarten war, haben große Lückengrößen und längere Wartezeiten größere, positive SHAP-Werte und tragen somit mehr zu einer Abbiegeklassifikation bei. Wie man in der Konfusionsmatrix in Abbildung 3.9 erkennen kann, reduziert die Kombination aus fNIRS und Kontextinformation die Anzahl der sicherheitskritischen Falsch-Negative. Um dies zu erklären können Abbiegesituationen mit niedrigen bzw. hohen Kontextfeaturewerten betrachtet werden. Abbildung 3.15 zeigt zwei SHAP-Beeswarm-Grafiken für das kombinierte Modell und eine Proband:in. Die linke Abbildung enthält nur Instanzen bei denen die Kontextvariablen unterdurchschnittliche Werte haben, dies bedeutet Instanzen mit kleineren Lückengröße und Wartezeiten. Entsprechend zeigt die rechte Abbildung nur Instanzen mit überdurchschnittlichen Kontextfeaturewerten. Außerdem zeigen die Abbildungen nur Instanzen bei denen das Kontextmodell falsch-negative Klassifikationen erzeugt und somit eine positive Abbiegeintention als *Nicht Abbiegen* klassifiziert. Alle Instanzen, welche in den Abbildungen dargestellt sind, wurden von dem kombinierten Modell richtig klassifiziert. Es zeigt sich, dass für niedrige Kontextfeaturewerte (links) bei denen die Proband:innen nach kurzen Wartezeiten und in kleine Lückengröße abgebogen sind, die fNIRS Feature höhere SHAP Werte also die Kontext Feature haben. Dies suggeriert, dass sie mehr zur korrekten Klassifikation des Modelles beitragen. Bei großen Kontextfeaturewerten (zum Beispiel lange Wartezeiten und große Lücken) hat die Lückengröße den größten Einfluss auf den Modelloutput. Das kombinierte Modell kann Informationen aus den fNIRS Features verwenden, um die korrekte Klassifikation in Situationen zu machen in denen die Kontextfeature versagen würden. In diesem Beispiel sind die fNIRS Informationen am wichtigsten in untypischen Abbiegesituationen mit kleinen Lücken und kurzen Wartezeiten. Dies legt nahe, dass die Hirnaktivität Informationen enthält, welche unabhängig vom Kontext die Abbiegeintention der Proband:in repräsentieren.

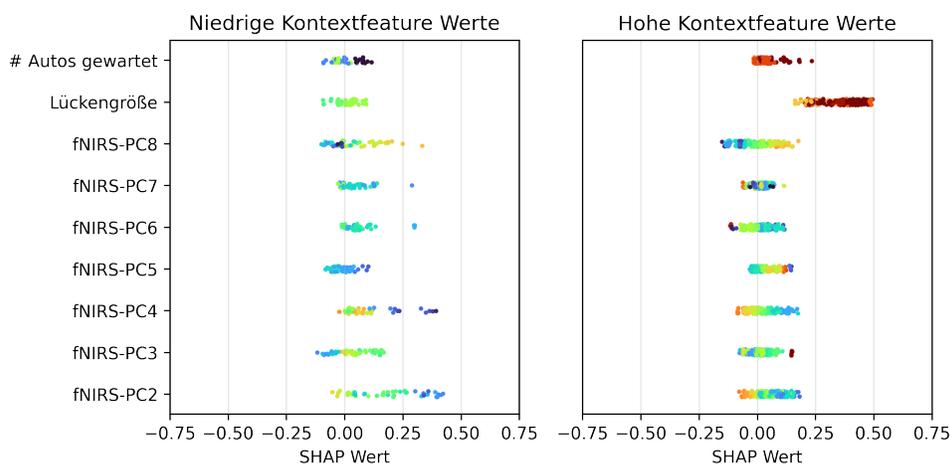


Abbildung 3.15: Beeswarm Abbildung der SHAP Werte für das kombinierte Modell und niedrige Kontextwerte.

Die hier präsentierte Studie hat jedoch einige Limitierungen. Zuerst hat das Abbiegeszenario nur wenige verwendbare Kontextvariablen. Es wurden hier nur die Lückengröße und die Wartezeit als Kontextvariablen verwendet. Andere Studien zum Abbiegeverhalten in ähnlichen Situationen empfehlen die Verwendung von weiteren Faktoren, wie Geschlecht, Alter oder Fahrstil [Pollatschek et al., 2002, Yan et al., 2007, Trende et al., 2021], welche einen Einfluss auf die Abbiegeentscheidung haben und somit das präsentierte Modell weiter verbessern können. Dies ist jedoch für die Modellierung auf Probandenlevel nicht möglich. Außerdem war die Stichprobengröße des Experimentes mit dreizehn Teilnehmer:innen relativ klein. Solche Stichprobengrößen sind in Studien mit neurophysiologischen Messverfahren wegen dem komplexen experimentellen Setup und der umfangreichen Datenverarbeitung gängig. Außerdem ist die Generalisierbarkeit von Modellen basierend auf neurophysiologischen Messverfahren nicht trivial. Somit ist eine Analyse auf Probandenlevel zu empfehlen.

Dies zeigt sich auch in der Auswertung der Modelle auf Gruppenlevel. Wie in Abbildung 3.14 zu sehen ist nimmt die AUC für eine zunehmende Anzahl an Proband:innen im Modell ab. Dieser Effekt führt zu einer Accuracy von 60% für das

fNIRS-Modell mit allen Proband:innen. Die AUC des Kontextmodelles nimmt mit steigender Zahl der Proband:innen im Modell leicht ab, allerdings nicht vergleichbar zum fNIRS Modell. Im Allgemeinen unterscheiden sich das kombinierte und das Kontextmodell nicht stark in der Performance. Dies liegt vor Allem daran, dass das kombinierte Modelle die Informationen aus den fNIRS-PC-Features wegen fehlender Generalisierbarkeit über Proband:innen hinweg nicht zur Klassifikation nutzen kann. Ein weiterer wichtiger Punkt ist die Nutzerakzeptanz von Gehirn-Computer Schnittstellen (*Brain-Computer Interface - BCI*). Eine Fahrer:in muss ein portables neurophysiologisches Messgerät tragen, damit ein Assistenzsystem, welches das hier präsentierte Modell nutzt, verwendet werden kann. Hierbei kann es zu Bedenken hinsichtlich der Datenaufzeichnung und insbesondere der Verwendung, Sicherheit und Speicherung der aufgezeichneten Daten seitens der Nutzer:in kommen. Bisher wurde die Nutzerakzeptanz von neurophysiologischer Sensorik vor Allem im Kontext von Patient:innen untersucht [Gentner and Classen, 2009, Gori et al., 2016, Blain-Moraes et al., 2012]. Hierbei ist die Nutzerakzeptanz der Technologie hoch. Grund hierfür ist vor Allem, dass der positive Nutzen der Datenerfassung, namentlich die Rehabilitation der Patient:in, klar für die Patient:innen ersichtlich ist. Für die Nutzerakzeptanz von neurophysiologischer Sensorik beziehungsweise Nutzerzustandserkennung gibt es derzeit keine Forschungsergebnisse. Die Anwendung von BCI für tägliche Tätigkeiten, wie das Autofahren, ist noch in einer sehr frühen Phase der Entwicklung und ist noch relativ weit von einer breiten Anwendung entfernt. Parallel zur Entwicklung und Erforschung eben solcher Methoden sollte jedoch auch die Untersuchung der Nutzerakzeptanz sein. Die Ergebnisse können so direkt beim Design und Entwicklung der Assistenzsysteme berücksichtigt werden. In Kapitel 5 wird auf das Thema und den aktuellen Stand der Forschung zur Akzeptanz von tragbarer, psychophysiologischer Sensorik eingegangen. Insbesondere durch die Markteinführung und Verbreitung von sogenannten *Wearables* wurden hierzu mehrere Nutzerakzeptanzstudien durchgeführt und auf mögliche Datenschutz Bedenken von potentiellen Nutzer:innen eingegangen.

3.6 Fazit

Ein funktionierendes Modell zur Intentionerkennung kann helfen sicherheitskritische Situationen oder sogar Unfälle im Straßenverkehr zu verhindern [Damm et al., 2019]. Hierbei könnte das Modell die Fahrer:in mithilfe einer Nutzerschnittstelle warnen oder eine Notbremsung initiieren. Die Integration von Hirnaktivitätsmessungen kann insbesondere in atypischen Abbiegesituationen von Nutzen sein und hierbei insbesondere in riskanten Situationen Fehlklassifikationen reduzieren. Abschließend lässt sich die Hypothese aufstellen, dass die Kombination von V2V Kommunikation, Kontextinformation und Modellen zur Intentionserkennung sicherheitskritische Situationen im Verkehr reduzieren kann. Ein solches System könnte nicht nur für die Erkennung der Abbiegeintention genutzt werden. Weitere denkbare Anwendungsfälle wären Überhol- oder Einfädelmanöver. Entsprechend zu Kapitel 5 könnte ein System mit neurophysiologischen Sensoren auch zur präziseren Nutzerzustandserkennung genutzt werden, um somit sicherheitskritische Situationen zu vermeiden, welche zum Beispiel durch Frustration, Müdigkeit oder hohe kognitive Last entstehen könnten.

Kapitel 4

Interaktion mit autonomen Fahrzeugen

4.1 Einführung

[Talebian and Mishra, 2018] prognostizieren, dass der Verkehr im Jahre 2050 zu 100% aus HAV bestehen kann, falls die Preise für autonome Fahrzeuge sich jährlich um 15% reduzieren. Bis ausschließlich HAVs im Straßenverkehr fahren wird es einen hybriden Verkehr zwischen von Menschen gesteuerten Fahrzeugen und HAVs geben. Aus diesem Grund ist es notwendig zu verstehen, wie Menschen mit HAV interagieren und umgekehrt. Für einen sicheren hybriden Straßenverkehr ist es wichtig, dass jede Teilnehmer:in die Interaktion beziehungsweise Handlungen des anderen richtig einschätzen kann und die korrekten Erwartungen an selbige hat. HAV wird in der Regel eine geringe Reaktionszeit und somit höhere Sicherheit prognostiziert [Nature Editorial, 2022]. Dies kann jedoch dazu führen, dass Menschen in der Interaktion mit HAV diese Reaktionszeit unterschätzen und somit Unfälle produzieren. An diesem Beispiel zeigt sich, dass das mentale Modelle, welches ein Mensch von der entsprechenden Interaktion beziehungsweise der Handlungsweise seines Gegenübers hat, äußerst wichtig ist. Mentale Modelle sind Repräsentationen eines Systems, welche vor Allem durch Interaktionen gelernt beziehungsweise aktualisiert werden

[Kurpiers et al., 2020]. Diese mentalen Modelle enthalten Informationen über die Eigenschaften, Fähigkeiten, aber auch Limitierungen eines Systems. Überschätzt der Mensch die Fähigkeiten, wie die Reaktionszeiten eines HAV, ist sein mentales Modell bezüglich des HAV nicht vollständig korrekt. Durch die Interaktion mit dem HAV kann diese inkorrekte Einschätzung korrigiert werden, indem die längere Reaktionszeit von dem Menschen während der Interaktion erlebt wird. Hierdurch kann es jedoch sicherheitskritischen Situationen kommen. Das mentale Modell sollte aktualisiert werden, um solche Unzulänglichkeiten zu verbessern. Hierzu kann zum Beispiel mehr Aufklärung zu den technischen Limitierungen von HAV betrieben werden. Außerdem können Mechanismen in ein HAV implementiert werden, welche dazu dienen, solche Fehleinschätzungen seitens des Menschen zu antizipieren und so sicherheitskritische Situationen vorzubeugen.

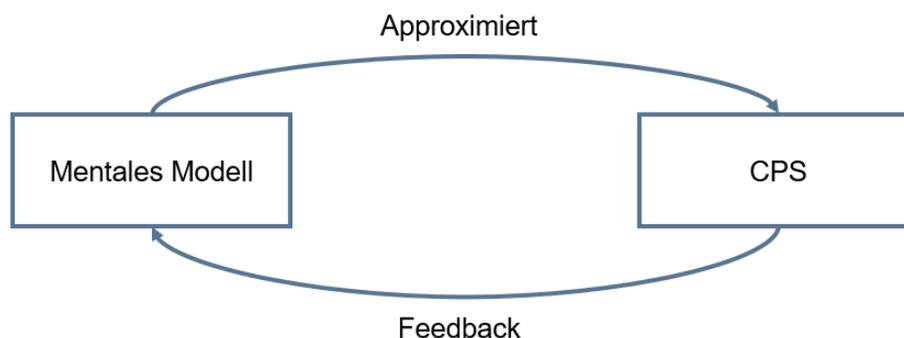


Abbildung 4.1: Der Mensch hat ein mentales Modell welches die Fähigkeiten und Verhaltensweise eines CPS approximiert. Durch die erfahrungsbasierte Interaktion mit dem CPS kann dieses mentale Modell aktualisiert werden.

Einige Studien haben gezeigt, dass Fußgänger:innen und menschliche Fahrer:innen das sichere und vorhersehbare Fahrverhalten von HAVs ausnutzen könnten. [Millard-Ball, 2018] zeigte, dass Fußgänger:innen sich einen Vorteil in der Interaktion mit HAVs verschafften. Sie gingen davon aus, dass HAVs an Zebrastreifen grundsätzlich

halten würden, sodass sie diese gefahrenlos überqueren können. Ähnliche Ergebnisse wurden von [Liu et al., 2020] berichtet. Fahrer:innen zeigten eine Bereitschaft in der Interaktion mit HAV aggressiver zu fahren, als sie das während der Interaktion mit menschlichen Fahrer:innen machen würden. Solche Handlungen könnte man als *Missbrauch von Automation* bezeichnen. Dieser Begriff wurde von [Parasuraman and Riley, 1997] geprägt. Einer dieser *Missbräuche von Automation* ist das blinde Vertrauen in die sichere Funktionalität der Automation. Dies kann bei der Interaktion mit solchen Automationsystemen zu sicherheitskritischen Situationen oder sogar Unfällen führen [Parasuraman and Manzey, 2010]. Ein solches blindes Vertrauen kann auftreten, wenn der Mensch die Limitierungen des Automationsystems nicht erkennt oder das Verhalten der Automation nicht richtig einschätzt oder beobachtet [Cunningham and Regan, 2015, Saffarian et al., 2012]. Es ist also wichtig zu verstehen, welches mental Modell und entsprechend welche Einschätzungen des Verhaltens bezüglich des Automationsystems die Menschen besitzen.

Im Folgenden werden zwei Studien vorgestellt, in denen Abbiegesituationen durch entgegenkommenden Verkehr als Beispiel für sicherheitskritische Verkehrssituationen verwendet werden. In diesen Situationen besteht beim Abbiegevorgang eine direkte Interaktion mit anderen Verkehrsteilnehmer:innen und sie eignen sich deshalb besonders für die Untersuchung von möglichen Unterschieden bei der Interaktion zwischen menschlichen Fahrer:innen und HAV. [Tay, 2007, Choi, 2010, Gerstenberger, 2015] berichten, dass 30-40% aller Unfälle im Straßenverkehr auf oder nahe bei Kreuzungen passieren. Grund hierfür ist vor Allem eine unzureichende Rücksichtnahme auf andere Verkehrsteilnehmer:innen [Vollrath et al., 2006, Biebl, 2021].

Im Folgenden werden die Ergebnisse zweier Studien präsentiert, welche das Ziel hatten, mögliche Unterschiede bei der Interaktion mit HAV im Vergleich zur Interaktion mit menschlichen Fahrer:innen während Abbiegesituationen zu untersuchen.

4.2 Material & Methoden

Die Hauptannahme bei der hier bearbeiteten Forschungsfrage war, dass HAV sich vorsichtiger und gesetzestreu als menschliche Fahrer:innen verhalten. [Millard-Ball, 2018] betrachtete die Interaktion zwischen Fußgänger:innen, welche die Straße über-

queren wollten und autonomen Fahrzeugen. Da HAV sich risikoavers verhalten sollen, ist es für Fußgänger:innen vorteilhaft vor einem HAV die Straße zu überqueren, da das HAV mit hoher Wahrscheinlichkeit bremsen wird. Dies führt zu der Hypothese, dass Menschen sich die defensive Programmierung der HAV zu Nutzen machen, um sich in zeitkritischen Situationen einen Vorteil zu verschaffen.

Hierfür wurde eine Fahrstudie im Fahr Simulator der Carl-von-Ossietzky Universität Oldenburg durchgeführt. Außerdem wurde von den Teilnehmer:innen nach dem Experiment ein Fragebogen zu Vertrauen in Automation, Fahrerfahrung, demographischen Daten und subjektivem Fahrstil ausgefüllt (s. 7.3). Beiden Studien liegt ein ähnliches experimentelles Paradigma zugrunde. In beiden Experimenten wurden Abbiegesituationen mit entgegenkommenden Verkehr im urbanen Raum verwendet.

In Abbildung 4.2 ist eine Abbiegesituation aus den Fahrstudien schematisch dargestellt. Die Teilnehmer:innen müssen an jeder Kreuzung wegen eines Stoppschildes zum stehen kommen. Anschließend warten sie an der Haltelinie bis sich eine passende Lücke zum Abbiegen ergibt. Den Teilnehmer:innen wird ein Zeitlimit für das Experiment gegeben, dessen Einhaltung zu einer monetären Belohnung führt. Außerdem wurden die Teilnehmer:innen vor dem Experiment instruiert, wie sie die autonomen Fahrzeuge im Verkehr erkennen können. Wie in 4.2 zu sehen ist wurde eine y-förmige Kreuzung für das Szenario gewählt. Dies vereinfacht den Proband:innen das Einschätzen der Lückengrößen. Der entgegenkommende Verkehr bestand aus simulierten, menschengesteuerten Fahrzeugen und simulierten HAV. Die HAVs waren stets gelbe Fiat C1 (s. 4.3) ohne 3D Modell einer Fahrer:in. Die menschlgesteuerten Fahrzeuge bestanden aus verschiedenen Fahrzeugtypen und Farben, wobei keines gelb war. Die Proband:innen wurden vor dem Experiment über diese Unterscheidung aufgeklärt. Außerdem wurden die Teilnehmer:innen instruiert, dass die HAV einem defensiven und risikoaversen Fahrverhalten folgen [Millard-Ball, 2018]. Im eigentlichen Experiment gab es jedoch keinen Unterschied im Fahrverhalten zwischen den simulierten HAV und HV.

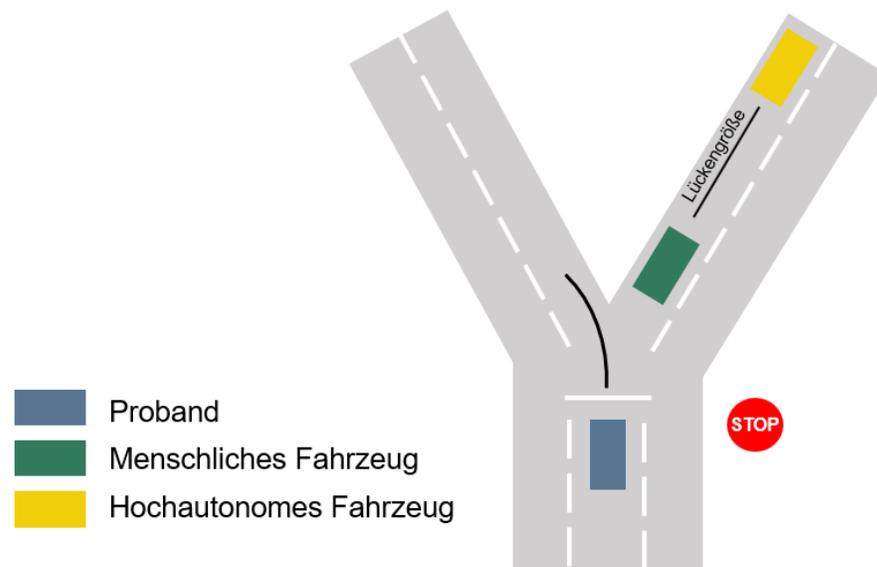


Abbildung 4.2: Skizze der simulierten Abbiegesituation. Der entgegenkommende Verkehr besteht aus HAV (gelb) und HV (grün). In der Simulation können HV verschiedene Farben und Fahrzeugtypen sein.



Abbildung 4.3: **Links:** HAV im Experiment waren immer gelbe Fiat C1 ohne Fahrer:in. **Rechts:** Die simulierten, menschgesteuerten Fahrzeuge konnten jede Farbe außer gelb haben. Des Weiteren wurde eine 3D Figur eines Menschen am Steuer dargestellt.

4.3 Studie 1: Unterschiede beim Abbiegeverhalten im hybriden Verkehr

4.3.1 Material & Methoden

Die erste der beiden Studien wurde mit 17 Teilnehmer:innen (7 männlich, 10 weiblich, mittleres Alter = 26.0 Jahre \pm 9.3, mittlere Fahrerfahrung = 8.6 Jahre) durchgeführt. Während des Experiments durchfuhren die Teilnehmer:innen zehn Kreuzungen in einem Block. An jeder Kreuzung mussten die Teilnehmer:innen wegen des entgegenkommenden Verkehrs stoppen. Die anderen Fahrzeuge im Verkehr fuhren mit einer Geschwindigkeit von 50 km/h. Der Abstand zwischen Fahrzeugen war so gering, dass Abbiegen zwischen den Fahrzeugen nicht möglich war. Es gab jedoch eine Lücke, welche das Abbiegen ermöglichte. Die Teilnehmer:innen hatten die Möglichkeit, die Lücke zu nehmen oder abzuwarten bis alle Fahrzeuge passiert sind. Nachdem die passierbare Lücke relativ klein war würde das Abbiegen durch die Teilnehmer:innen das andere Fahrzeug zum Bremsen zwingen. In fünf der Kreuzungen war das Fahrzeug nach der Lücke ein HAV. In den restlichen fünf Kreuzungen war es ein HV.

Das Experiment bestand aus drei Blöcken: der erste Block war eine Trainingseinheit, damit sich die Teilnehmer:innen an die Dynamik des Fahrsimulators gewöhnen konnten. Im zweiten oder dritten Block wurde das oben beschriebene experimentelle Paradigma angewendet. Randomisiert wurde Teilnehmer:innen im zweiten oder dritten Block ein Zeitlimit gegeben, um einen Lerneffekt zu verhindern. Die Teilnehmer:innen konnten eine zusätzliche monetäre Belohnung bekommen, wenn sie den entsprechenden Block innerhalb des Zeitlimits abschließen konnten.

Nach dem Experiment füllten die Teilnehmer:innen einen Fragebogen zu Vertrauen in autonome Fahrzeuge aus (s. 7.3). Der Fragebogen enthielt außerdem Fragen zu demographischen Daten und Fahrerfahrung der Teilnehmer:innen. Die Fragen konnten auf einer Sechs-Punkte Skala bewertet werden, wobei eine Wertung von Sechs der höchste Übereinstimmung entspricht.

4.3.2 Ergebnisse

Basierend auf den Fahrsimulatorendaten wurde der prozentuale Anteil der akzeptierten Lücken im Bezug auf den entsprechenden Interaktionspartner bestimmt. Die Prozentzahlen wurden über alle Teilnehmer:innen gemittelt. Außerdem wurden die Mittelwerte und Standardabweichungen der quantitativen Fragen des Fragebogens berechnet.

Insgesamt wurden 168 Abbiegesituationen mit Zeitlimit und 170 ohne Zeitlimit analysiert. Zwei Abbiegesituationen mit Zeitlimit konnten wegen technischer Probleme nicht analysiert werden. Im experimentellen Block ohne Zeitlimit haben die Teilnehmer:innen in 27.1% der Kreuzungen die Lücke genommen, wenn der Interaktionspartner ein HAV war (s. 4.2). Entsprechend haben sie in 72.9% der Kreuzungen gewartet. In den Kreuzungen ohne HAV haben die Teilnehmer:innen in 34.1% die Lücke genommen. In den Blöcken mit Zeitlimit ist die Anzahl der akzeptierten Lücken signifikant angestiegen. Die Teilnehmer:innen nahmen 89.0% der Lücken mit HAV und 69.4% der Lücken ohne HAV. Der Unterschied zwischen diesen beiden Versuchsbedingungen war basierend auf einem Chi-Quadrat-Test signifikant ($p = 0.002$).

Diese Resultate decken sich auch mit den Ergebnissen des Fragebogens. Die mittlere Werte für alle Fragen im Bezug auf Vertrauen in HAV war 3.90 ± 1.44 , was wiederum auf eine überdurchschnittliche Zustimmung mit den gegebenen Fragen hindeutet. Insgesamt suggerieren die Ergebnisse, dass menschliche Fahrer:innen in zeitkritischen Situationen tendenziell eher vor HAV als vor anderen menschlichen Fahrer:innen abbiegen würden.

	Ohne Zeitlimit (N=170)	Mit Zeitlimit (N = 168)
Mensch (%)	34.1	69.4
HAV (%)	27.1	89.0

Tabelle 4.1: Prozentualer Anteile an akzeptierten Lücken nach Versuchsbedingung

4.4 Modellierung des Abbiegeverhaltens im hybriden Verkehr

4.4.1 Modellierung

Basierend auf den Daten aus der in Abschnitt 4.3 beschriebenen Studie wurde das Abbiegeverhalten der Proband:innen im hybriden Verkehr modelliert. Wie bereits in Abschnitt 3.3 wurde auch hier ein Bayessches Netz für die Modellierung und Klassifikation des Abbiegeverhaltens verwendet [Damm et al., 2019]. Das Modell enthielt nur vier binäre Zufallsvariablen: Abbiegen (A), Zeitlimit (ZL), Interaktionspartner (IP) und Geschlecht (G). ZL , IP und G sind unabhängig voneinander. A hängt in unserem Modell von ZL , IP und G ab (s. Abb. 4.4). Somit ergibt sich eine gemeinsame Wahrscheinlichkeitsverteilung von:

$$p(A, ZL, IP, G) = p(A|ZL, IP, G)p(ZL)p(IP)p(G) \quad (4.1)$$

wobei $M \in \{wahr, falsch\}$, $ZL \in \{wahr, falsch\}$, $G \in \{maennlich, weiblich\}$ und $IP \in \{HAV, HV\}$.

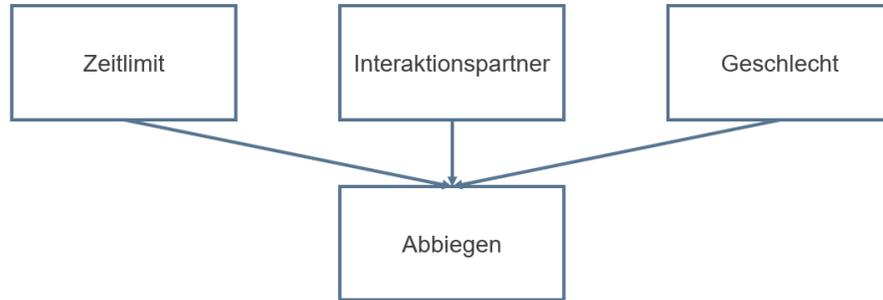


Abbildung 4.4: Schematische Darstellung des Bayesschen Netzes zur Klassifikation der Abbiegeentscheidung im hybriden Verkehr.

Die Wahrscheinlichkeiten für ZL , G und IP wurden entsprechend des experimentellen Paradigmas bzw. den demographischen Fragebogen der Teilnehmer:innen

definiert. $p(ZL = \text{wahr}) = 0.5$, da jede Teilnehmer:in im Experiment gleich viele Kreuzungen mit und ohne Zeitlimit durchfuhren. Die Anzahl an Kreuzungen mit HAV im Experiment war ebenfalls balanciert, sodass $p(IP = HAV) = 0.5$. Obwohl doppelt so viele weibliche wie männliche TeilnehmerInnen an der Studie teilnahmen ist $p(G = \text{weiblich}) = 0.59$. Grund hierfür ist, dass aus technischen Gründen ein Teil der Daten für die Auswertung nicht verwendet werden konnte. Ein Vorteil der Modellierung von Abbiegeentscheidungen mit Bayesschen Netzwerken ist ihre Eigenschaft, Inferenz durchführen zu können ohne die Werte aller Variablen zu kennen. Wir nutzen diese Eigenschaft aus, um zu zeigen wie die Integration der verschiedenen Variablen sich auf die Klassifikationsmetriken des Modells auswirken. Hierfür evaluieren wir vier verschiedene Modelle. Jedes Modell unterscheidet sich in der Anzahl an beobachteten Variablen beziehungsweise wieviel Evidenzen bekannt sind. Es wird die Receiver Operating Characteristic mit einer 10-fold Kreuzvalidierung berechnet. Anschließend werden die Accuracy, Falsch-Negativ-Raten (FNR) und Area-Under-Curves (AUC) verglichen. Die FNR entspricht der Wahrscheinlichkeit, dass die Teilnehmer:in abgelenkt ist, wobei das Modell klassifiziert, dass die Teilnehmer:in wartet. Hierbei handelt es sich um die sicherheitskritischsten Situationen in diesem Anwendungsfall.

4.4.2 Ergebnisse

Sowohl die Accuracy, als auch die AUC verbessert sich, wenn dem Modell mehr Evidenzen zur Verfügung stehen. Das beste Modell $P(M|ZL, IP, G)$ hat eine Accuracy von 80% und eine $AUC = 0.81$. Insbesondere Evidenzen über das Zeitlimit und somit einen Zeitdruck der Proband:in führt zu allgemein besseren Ergebnissen. Das Modell $p(M|IP, G)$ erreicht nur eine Accuracy von 68% und eine $AUC = 0.62$. Da alle Modelle, welche Evidenzen über das Zeitlimit enthalten, generell die besten Ergebnisse produzieren, lässt sich vermuten, dass diese Variable des Modelles den größten Einfluss auf den Modelloutput hat. Im Allgemeinen unterscheiden sich die Accuracys und AUCs zwischen den Modellen mit Evidenzen für das Zeitlimit nicht signifikant. Um die Wahrscheinlichkeit für Unfälle und sicherheitskritische Situationen zu minimieren sollte jedoch das Modell $p(M|ZL, IP)$ verwendet werden, da es

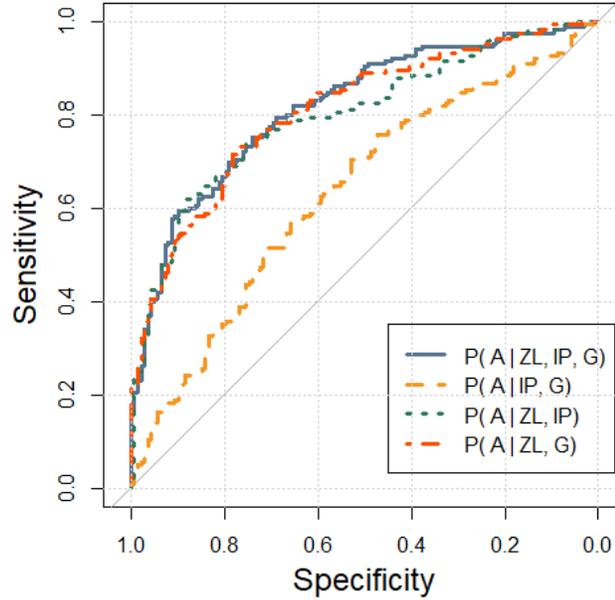


Abbildung 4.5: ROC Kurve für alle vier Modelle zur Erkennung der Abbiegeintension.

die niedrigste FNR aufweist.

	$p(M ZL, IP, G)$	$p(M IP, G)$	$p(M ZL, G)$	$p(M ZL, IP)$
AUC	0.81 ± 0.01	0.62 ± 0.01	0.78 ± 0.07	0.80 ± 0.01
Accuracy	0.80 ± 0.01	0.68 ± 0.01	0.78 ± 0.01	0.78 ± 0.01
FNR	0.26 ± 0.02	0.30 ± 0.04	0.27 ± 0.03	0.22 ± 0.03

Tabelle 4.2: Ergebnisse des Modellvergleichs mit 10-fold Kreuzvalidierung. Modelle, welche Evidenzen für das Zeitlimit enthalten haben im Allgemeinen bessere Werte für alle Metriken.

4.5 Studie 2: Unterschiede in der gewählten Lückengröße beim Abbiegeverhalten im hybriden Verkehr

4.5.1 Material & Methoden

Wie bereits in der vorhergehenden Studie bestand auch hier das Experiment aus mehreren Linksabbiegesituationen mit entgegenkommendem Verkehr im urbanen Raum (s. Abschnitt 4.2). Die Verteilung der entgegenkommenden Fahrzeuge wurde an die Ergebnisse von [Ragland et al., 2005] angelehnt und als lognormale Verteilung konstruiert. [Ragland et al., 2005] fanden heraus, dass die meisten Lücken 4s oder kürzer waren, wobei die häufigsten Lücken beziehungsweise Abstände zwischen zwei Fahrzeugen 2s betragen. Aus diesem Grund wurden in dieser Studie Lückengrößen zwischen 1 und 6 Sekunden verwendet. Die Fahrzeuge, welche als erstes an der Kreuzung ankommen haben, eine geringe Lückengröße angelehnt an [Yan et al., 2007]. Dies ermöglicht, dass die Proband:innen die für sie minimal akzeptable Lückengröße präsentiert bekommen. Hierbei haben die ersten 4 bis 6 Autos eine Lückengröße zwischen 1 und 3 Sekunden. Die folgenden Autos haben eine Lückengröße zwischen 3.5 und 6 Sekunden.

Insgesamt fuhren die Teilnehmer:innen 100 Abbiegemanöver in 10 Blocks a 10 Kreuzungen. Zwischen jeder Kreuzung hatten die Teilnehmer:innen eine Pause von 1 bis 1:30 Minuten. Insgesamt dauerte das gesamte Experiment etwa 70 Minuten. Die Teilnehmer:innen hatten ein Zeitlimit von 5:30 Minuten für jeden der zehn Blöcke. Für jeden Block innerhalb des Zeitlimits erhielten die Proband:innen 1 Euro. Um das Zeitlimit einzuhalten mussten die Proband:innen eine der Lücken im entgegenkommenden Verkehr nehmen und konnten nicht warten bis alle entgegenkommenden Fahrzeuge passiert waren. Insgesamt wurden nur zwei der 1200 Abbiegemanöver durchgeführt nachdem alle Fahrzeuge passiert waren.

Nach der Fahrsimulation füllten die Proband:innen einen Fragebogen mit vier Fragen zu Vertrauen in HAV aus. Diese waren: *Ich akzeptiere HAVs auf der Straße*, *HAVs sind sicherer als HV*, *Ich vertraue HAVs mehr als HV* und *Ich habe mich bei der*

Interaktion mit HAVs anders verhalten als bei der Interaktion mit HV (s. 7.3).
Wie bereits in anderen Studien beschrieben [Fitzpatrick, 1991, Ragland et al., 2005], wurde die Lückenakzeptanzwahrscheinlichkeit für jede Lückengröße und alle Proband:innen berechnet. Logistische Modelle für die Wahrscheinlichkeit der Lückenakzeptanz wurden für die Interaktion mit HAV und HV gefittet, wobei die Lückengrößen in 0.35s Schritte gruppiert wurden. Das Modell hat zwei Regressionsparameter zu optimieren:

$$P(\text{gap}_m, w) = \frac{1}{(1 + \exp(-2\log(\frac{1}{0.05-1})\frac{X-m}{w}))} \quad (4.2)$$

Hierbei ist m der Schwellwert, welcher die 50% Lückenakzeptanzwahrscheinlichkeit angibt. w ist die Weite des Modells, welche den Unterschied zwischen dem 5% und 95% Punkt der Lückenakzeptanzwahrscheinlichkeit des Modells angibt. Die logistischen Modelle wurden mithilfe der psignifit 4 Toolbox [Schütt et al., 2015] gefittet.

4.5.2 Ergebnisse

Wegen Unwohlsein im Fahrsimulator musste das Experiment für eine Proband:in abgebrochen werden und somit konnten die Daten für die Auswertung nicht verwendet werden. Insgesamt wurden Daten von 12 Proband:innen ausgewertet. Die Ergebnisse für den Fragebogen finden sich in 4.3. Der Mittelwert über alle Fragen zu Vertrauen in HAV war 3.8 (von maximal 5), was auf ein hohes Vertrauen in Automation hindeutet. Das Cronbach Alpha für diese Fragen ist 0.78, was eine akzeptable Reliabilität dieser Fragen suggeriert. Des Weiteren haben 7 der 12 Teilnehmer:innen angegeben, dass sie bevorzugt vor den HAV abgebogen sind. Die restlichen 5 Teilnehmer:innen hatten keine Präferenz beim Abbiegen. Es ist möglich, dass die Teilnehmer:innen das Abbiegen vor HAV, wegen des suggerierten defensiven Fahrstils präferiert haben, um einen zeitlichen Vorteil im Experiment zu gewinnen.

Aussage	Bewertung
Ich akzeptiere HAV auf der Straße	4.0 ± 1.5
HAVs sind sicherer als HVs	3.9 ± 1.4
Ich vertraue HAVs mehr als HVs	3.9 ± 1.2
Ich habe mich bei der Interaktion mit HAVs anders verhalten, als bei der Interaktion mit HVs	3.2 ± 1.2
Mittelwert	3.8 ± 0.9

Tabelle 4.3: Ergebnisse des Fragebogens zu Vertrauen in HAV.

Abbildung 4.6 zeigt die Lückenakzeptanzwahrscheinlichkeit in Abhängigkeit von der jeweiligen Lückengröße. Für die Interaktion mit HAVs und HVs wurde jeweils ein logistisches Modell gefittet. Die Lückengrößen wurden in 0.35 Sekunden Zeitschritten gruppiert und Abbiegesituationen von allen Teilnehmer:innen wurden gemeinsam analysiert. Der Weiteparameter w des Modells beschreibt den Unterschied zwischen der 5% und 95% Lückenakzeptanzwahrscheinlichkeit und liegt für HAVs bei $w_{HAV} = 0.65s(0.59s - 1.25s)$ und für HVs bei $w_{HV} = 4.17s(2.87s - 5.04s)$. Somit hat das logistische Modell für die Interaktion mit HAV eine stärkere Steigung als das Modell für HV (s. Abbildung 4.6). Dies könnte darauf hindeuten, dass sich die Proband:innen bei der Abbiegeentscheidung mit HAV leichter getan haben. Dies wird durch die kleinere Varianz der Lückenakzeptanz suggeriert.

Die Schwellwerte der Modelle für die 50% Lückenakzeptanz sind für die Interaktion mit HAV $m_{HAV} = 3.09s$ (2.96s - 3.20s) und für HV $m_{HV} = 3.08s$ (2.75s - 3.30s). Der Überlapp der beiden Konfidenzintervalle deutet darauf hin, dass die beiden Modellparameter sich nicht signifikant unterscheiden.

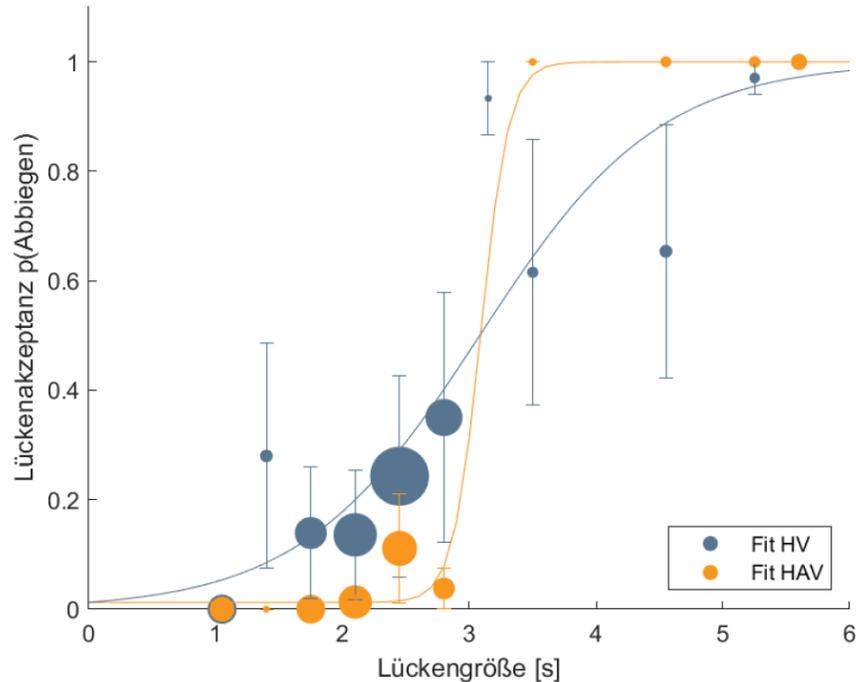


Abbildung 4.6: Lückenakzeptanzwahrscheinlichkeit in Abhängigkeit von Lückengröße und Interaktionspartner. Außerdem gefittete logistische Modelle für die Interaktion mit HAV (orange) und HV (blau).

4.6 Diskussion

In Studie 1 wurde die Interaktion von menschlichen Fahrer:innen im Umgang mit HAV in zeitkritischen Abbiegesituationen untersucht. Es konnte gezeigt werden, dass die Teilnehmer:innen unter Zeitdruck öfters vor HAV (89.0%) abgebogen sind als vor HV (69.4%). Die Teilnehmer:innen der Studie wurden vor Beginn des Experiments instruiert, dass die simulierten HAV einem defensiven und risikoaversen Fahrverhalten folgen, wobei im eigentlichen Experiment alle Fahrzeuge dem gleichen Fahrverhalten entsprechend simuliert wurden. Sowohl im industriellen wie auch wissenschaftlichen Kontext ist das Narrativ, dass autonome Fahrzeuge nicht nur defensiv und risikoavers fahren, sondern auch durch ihre Technologie sichere Verkehrsteilnehmer:innen sind

[Nature Editorial, 2022]. Diese Erwartung könnte die Proband:innen dazu verleitet haben das defensive Fahrverhalten auszunutzen, um sich einen zeitlichen Vorteil zu verschaffen, welcher wiederum zu einer zusätzlichen monetären Belohnung führte. Dies kann zu gefährlichen Verkehrssituationen oder sogar Unfällen führen [Parasuraman and Manzey, 2010].

Basierend auf den Studiendaten der oben beschriebenen Studie wurde ein Bayessches Netz zur Erkennung der Abbiegeintension im hybriden Verkehr erstellt. Es wurden vier unterschiedliche Varianten dieses Modelle verglichen, wobei jeder Variante eine andere Menge an Evidenzen über die im Modell repräsentierten Zufallsvariablen zu Verfügung stand. Modelle, welche Evidenzen über Zeitdruck bei den Proband:innen enthielten haben im Vergleich am besten abgeschnitten.

Die Wahrscheinlichkeiten der Zufallsvariablen im Modell wurden anhand des experimentellen Settings gewählt. [Sivak and Schoettle, 2012] fanden heraus, dass im Jahre 2010 in den USA 50.3% aller Fahrer:innen weiblich waren, wobei Männer insgesamt 59.0% der mit dem Auto zurückgelegten Gesamtdistanz fahren. Entsprechend ist die Wahrscheinlichkeit mit einem männlichen Fahrer im Straßenverkehr zu interagieren höher und es wäre empfehlenswert, die Wahrscheinlichkeiten für $p(G)$ entsprechend anzupassen. Außerdem sollte $p(IP)$ angepasst werden. Im Experiment war die Anzahl an Kreuzungen mit einem HAV als Interaktionspartner gleich der Anzahl an Kreuzungen ohne HAV. Die Anzahl an HAV im Straßenverkehr wird über eine längere Zeit ansteigen und muss entsprechend angepasst werden. Die Auswertung der Modell suggeriert, dass $p(ZL)$ die wichtigste Zufallsvariable für die Abbiegeintension in diesem Modell ist. Es ist nicht klar welche und wieviele Menschen im Allgemeinen unter Zeitdruck fahren. Mithilfe von neurophysiologischen Sensoren, wie zum Beispiel fNIRS, könnte Zeitdruck beziehungsweise Stress bei der Fahrer:in erfasst werden. Die Ergebnisse aus Kapitel 3 zeigen, dass generell eine Nutzung von neurophysiologischen Sensoren und integrierten Modellen, welche neben nutzerspezifischen Daten auch Kontextinformationen verwenden, empfehlenswert ist.

In einer zweiten Studie wurde ein ähnliches experimentelles Paradigma verwendet, jedoch wurde hierbei der Fokus nicht auf der Abbiegewahrscheinlichkeit im Bezug auf den Interaktionspartner untersucht. Der Fokus der Studie lag vielmehr auf der Größe der akzeptierten Lücke im Bezug auf den Interaktionspartner. Die Lückengröße

beim Abbiegen durch den entgegenkommenden Verkehr ist der wichtigste Faktor für ein sicheres Abbiegemanöver. Studien wie [Millard-Ball, 2018] legen nahe, dass Menschen das angeblich defensive Verhalten von HAV ausnutzen könnten. Dies führte uns zu der Hypothese, dass Menschen bei Abbiegemanövern vor HAV eventuell kleine Lückengrößen und somit ein höheres Sicherheitsrisiko akzeptieren würden, um sich einen zeitlichen Vorteil zu verschaffen.

Die Resultate des Lückenakzeptanzmodells zeigen, dass die Konfidenzintervalle des Schwellwertparameters m überlappen. Dies weist daraufhin, dass die Parameter nicht signifikant verschieden sind und somit auch kein signifikanter Unterschied bei den Sicherheitsabständen beim Abbiegen mit HAV oder HV bestand. Es konnte allerdings ein Unterschied beim Weiteparameter w des Modells festgestellt werden. Dieser suggeriert, dass die Lückenakzeptanzverteilung für HAV deutlich steiler als der selbe Parameter für das HV Modell ist. Die stärkere Steigung des Modells für HAV lässt vermuten, dass die Teilnehmer:innen sich beim Entscheidungsprozess vor einem HAV sicherer waren. Entsprechend suggeriert die flachere Steigung für das HV Modell, dass die Teilnehmer:innen bei der Interaktion mit HV unsicherer waren. Wir nehmen an, dass die Teilnehmer:innen sich bei der Interaktion mit HAV sicherer waren, weil die HAV als vorhersehbarer einschätzten und eventuell einen zeitlichen Vorteil erhalten wollten. Diese Annahme wird durch die Ergebnisse des Fragebogens zu Vertrauen in HAV gestützt. Der mittlere Wert für die Aussage *Ich vertraue HAVs mehr als HVs* war 3.9 auf einer Skala von 1-5. Dies führt zu der Annahme, dass die Teilnehmer:innen das vermeintlich defensive Fahrverhalten der HAV überschätzen und gleichzeitig die technischen Limitierungen des HAV unterschätzten. Dieses *automation complacency* bezüglich der sicheren Funktionalität der HAV kann potentiell zu gefährlichen Situationen führen [Parasuraman and Riley, 1997].

Sieben von 12 Teilnehmer:innen haben in unserer Studie erwähnt, dass sie eine Lücke vor HAVs bevorzugt haben, weil sie annahmen, dass das HAV wegen seiner defensiven Fahrstrategie bremsen würde. Dies ist eine gefährliche Annahme, da alle Fahrzeuge in der Simulation (HAV und HV) mit dem gleichen Fahrverhalten simuliert wurden. Die Teilnehmer:innen überschätzten das Verhalten der HAV basierend auf der angeblich defensiven Programmierung. Dies ist ein klassisches Beispiel von *misuse of automation* wie es von [Parasuraman and Riley, 1997] als Überschätzung von Au-

tomation definiert ist. Im Falle von Überschätzung von Reaktionszeiten von HAV oder Sensorausfällen kann es zu gefährlichen Verkehrssituationen oder sogar Unfällen kommen [Parasuraman and Manzey, 2010].

Die durchgeführte Studie hat einige Limitierungen. Das experimentelle Design hatte nicht ausreichend Lücken im Bereich drei bis sechs Sekunden. Dies führte zu weniger Abbiegeentscheidungen mit diesen Lückengrößen. Es sollte außerdem erwähnt werden, dass es sich um eine relativ homogene Teilnehmergruppe handelte. Alle Teilnehmer:innen waren relativ jung (mittleres Alter = 26 Jahre) und viele haben einen akademischen Hintergrund. Hieraus lässt sich gegebenenfalls auf ein überdurchschnittliches Vertrauen in Technologie schließen [Kennedy et al., 2008]. Dies könnte einen Einfluss auf die Fragebogenergebnisse in Tabelle 4.3 und das damit verbundene Vertrauen in HAV haben. Wir erwarten, dass sich Menschen mit niedrigem Vertrauen in HAV bei der Interaktion mit solchen anders verhalten würden. Eine Möglichkeit wäre, dass sie sich nicht so sicher bei der Interaktion mit den HAV fühlen würden. Somit wäre die Steigung des logistischen Modells für die Interaktion mit HAV flacher. Die Modelle in dieser Studie wurden nur in Abhängigkeit der Lückengröße und des Interaktionspartners gefittet. Einige Studien argumentieren, dass die Lückengröße auch von persönlichen Charakteristiken, wie dem Alter, Geschlecht oder Layout der Kreuzung abhängt [Bottom and Ashworth, 1978, Darzentas et al., 1980, Yan et al., 2007]. Solche Faktoren wurden in dieser Studie nicht beachtet und sollten in zukünftigen Arbeiten mitberücksichtigt werden.

4.7 Fazit

Menschen haben ein mentales Modell, welches unter Anderem eine gewisse Erwartung über die Handlungsweise und Fähigkeiten des Interaktionspartners beinhaltet. Solche Interaktionspartner können nicht nur andere Menschen oder Lebewesen, sondern können auch CPS wie HAV sein. Die Erforschung von mentalen Modellen für die Interaktion mit CPS kann helfen, Leitlinien für eben jene Interaktion beziehungsweise das Design des CPS zu entwerfen, um die Interaktion effizienter und sicherer zu gestalten. Solche Forschungsarbeiten bieten sich vor der Einführung des HCPS in den Alltag an, um sicherheitskritische Situationen zu vermeiden, welche auch dem

weiteren Adoptionsprozess der Technologie im Wege stehen können.

Das Ziel diese beiden hier präsentierten Studien war mögliche Verhaltensunterschiede bei zeitkritischen Interaktionen von HV und HAV beziehungsweise HV und HV zu untersuchen. Hierbei wurden Abbiegesituationen als Anwendungsfall verwendet, welche eine von vielen Verkehrssituationen darstellt in denen HV mit HAV in einem hybriden Verkehr interagieren werden. Es ist von großer Wichtigkeit mögliche Verhaltensunterschiede zu untersuchen, um potenzielle sicherheitskritischen Risiken im Idealfall vor der Einführung von HAV in den Straßenverkehr zu erkennen. Dies ermöglicht Forscher:innen und Entwickler:innen von HAV dieses womöglich unerwartete Verhalten bei der Entwicklung von HAV zu beachten. In diesen Studien konnte gezeigt werden, dass die Proband:innen sich die angeblichen technologischen Vorteile, wie schnelle Reaktionszeit und ein defensives und risikoaverses Fahrverhalten eines HAV zu Nutzen machen könnten, um sich in zeitkritischen Situationen einen Vorteil zu verschaffen. Ähnliche Ergebnisse wurden unter Anderem auch von [Millard-Ball, 2018] und [Liu et al., 2020] präsentiert.

Kapitel 5

Unsicherheitserkennung im autonomen Fahren

5.1 Einführung

In den letzten Jahren hat sowohl die Wissenschaft als auch die Industrie viel Aufwand betrieben, um die Entwicklung von autonomen Fahrzeugen voranzutreiben. Für eine erfolgreiche Integration von autonomen Fahrzeugen in den Straßenverkehr muss jedoch nicht nur die Automationstechnologie sicher funktionieren, sondern die Technologie muss auch von den potentiellen Nutzer:innen akzeptiert und verwendet werden. Hierfür sollte die Fahrt mit einem autonomen Fahrzeug so komfortabel wie möglich sein. Dies fördert Akzeptanz und Vertrauen in die Technologie [Paddeu et al., 2020] und kann die Einführung der Technologie in den Alltag beschleunigen. Dieser Fahrkomfort kann jedoch vermindert werden, wenn sich das autonome Fahrzeug nicht entsprechend den Erwartungen oder Präferenzen der Nutzer:in verhält [Dettmann et al., 2021]. Entsprechend sollte das Verhalten des autonomen Fahrzeuges an diese Bedürfnisse der Nutzer:innen angepasst werden können [Trende et al., 2019a]. Ein wichtiger Schritt für eine automatisierte Anpassung ist, dass die Unsicherheit und der damit einhergehende Diskomfort automatisch vom Fahrzeug erkannt wird. Anschließend kann das Fahrzeug sein Verhalten entsprechend anpassen, um

eine komfortablere Fahrerfahrung zu gewährleisten [Drewitz et al., 2019, Drewitz et al., 2020]. In der Vergangenheit haben bereits viele ForscherInnen die Messung beziehungsweise Erkennung von Diskomfort beziehungsweise Unsicherheit bei der Fahrzeugnutzung erforscht [Beggiato et al., 2019, Paddeu et al., 2020, Radhakrishnan et al., 2020, Roßner et al., 2019, Dillen et al., 2020]. Der gängigste Ansatz ist hierbei die Verwendung von psychophysiologischen Messverfahren, wie Elektrokardiographie oder Pupillometrie, um ein erhöhtes Level an Stress zu messen. Obwohl es einen Unterschied zwischen subjektiver Unsicherheit und Stress gibt, wird meist ein ähnlicher methodologischer Ansatz verwendet werden. [Beggiato et al., 2018] untersuchte die Möglichkeit, subjektive Unsicherheit mittels physiologischer Parameter wie Herzrate oder elektrodermalen Hautleitfähigkeit zu messen. Basierend auf den Ergebnissen einer Fahrsimulatorstudie mit 40 Teilnehmer:innen schlussfolgerten die Forscher:innen, dass die Herzrate ein sinnvoller Indikator zur Bestimmung von Unsicherheit im simulierten autonomen Fahren ist. In dieselbe Richtung weisen [Healey and Picard, 2005], welche psychophysiologische Sensoren wie ein Elektrokardiogramm, Elektromyogramm und Hautleitfähigkeit verwendeten, um Stress während Fahraufgaben im realen Straßenverkehr zu messen. [Telpaz et al., 2018] benutzen kontextuelle Information, die von einer nach vorne gerichteten Kamera auf der Motorhaube aufgenommen wurde, um ein Modell zu konstruieren, welches das Unwohlsein der Passagiere klassifizieren kann. Diese Daten wurden in einer Realfahrtstudie mit 19 Teilnehmer:innen in einer urbanen Umgebung aufgezeichnet. Die Wissenschaftler:innen verwendeten Abstände und die Zeit bis zur Kollision mit anderen Verkehrsteilnehmer:innen als Parameter für ihr Modell. Bei dem verwendeten Modell handelte es sich um ein logistisches Regressionsmodell, wobei mehrere unterschiedliche Kombinationen an Variablen verglichen wurden. Die Forscher:innen fanden heraus, dass die Hinzufügung von kontextuellen Parametern zu einem Modell, das ausschließlich aus Fahrdynamikdaten erstellt wurde, die Detektion von Unwohlsein verbessert. [Ping et al., 2018] trainierte ein Long Short-Term-Memory Netzwerk, um die Risikowahrnehmung der Teilnehmer:innen zu modellieren. Hierbei verwendeten sie kontextuellen Variablen wie etwa dem Zustand des Ego-Fahrzeugs (z.B. Beschleunigung oder Steuerung) und den Zustand anderer Verkehrsteilnehmer und Informationen über das Straßenlayout. Das beste Modell konnte eine Accuracy von

etwa 81.5% erreichen. [Dommel et al., 2021] verglich ein Support Vector Machine und ein logistisches Regressionsmodell zur Klassifikation von Diskomfort beim simulierten Fahren mithilfe von psychophysiologischen Messverfahren, wie Herzrate, Blinzelfrequenz und Pupillendurchmesser. Beide Modelle erreichten eine Accuracy von etwa 72%. Die Autoren vermuten, dass die Accuracy durch Hinzunahme von mehr psychophysiologischen Messverfahren, wie Körperbewegung, weiter verbessert werden könnte. Auch [He et al., 2022] konnten in ihrer Fahrsimulatorstudie mit 25 Teilnehmer:innen zeigen, dass Herzrate und Pupillendurchmesser gute Indikatoren für das wahrgenommene Risiko beim autonomen Fahren sind. Zudem fanden die Forscher:innen eine mittlere Korrelation für teilnehmerspezifische Charakteristika wie Geschlecht und Fahrerfahrung.

Aufgrund der oben erläuterten Forschung stellen wir die Hypothese auf, dass die Integration von kontextuellen, psychophysiologischen und nutzerspezifischen Parametern die Erkennung von Unsicherheit bei hoch automatisierten Überholmanövern verbessern kann. Hierzu wurde eine Fahrsimulatorstudie mit 50 Teilnehmer:innen an der Technischen Universität Chemnitz durchgeführt. Die in der Studie erhobenen Daten wurden genutzt, um ein Klassifikationsmodelle für subjektive Unsicherheit beim simulierten, autonomen Fahren zu trainieren. Der Vergleich verschiedener Featurekombinationen zeigt, dass eine Integration von kontextuellen, psychophysiologischen und nutzerspezifischen Parametern zu den besten Ergebnissen führt.

5.2 Material & Methoden

Eine Fahrsimulatorstudie mit 50 Proband:innen (28 weiblich, 22 männlich) wurde am Fahrsimulator der Technischen Universität Chemnitz durchgeführt (s. 2.4 und [Hartwich et al., 2020]). Die Proband:innen der Studie waren zwischen 20 und 43 Jahre (Mittelwert = 25.9, Standardabweichung = 4.7) alt und besaßen einen gültigen deutschen Führerschein. Das Fahrscenario umfasste eine 7 km lange Strecke, welche aus 4 km im Stadtverkehr mit einem Geschwindigkeitslimit von 50 km/h und einer 3 km langen Landstraße mit Geschwindigkeitslimit von 100 km/h, bestand. Während dieses Fahrscenario führte das simulierte autonome Fahrzeug drei Überholmanöver aus. Hierbei musste das autonome Fahrzeug auf die Gegenseite wechseln um ein Hin-

dernis zu umfahren. Bei den Hindernissen handelte es sich um einen Bus an einer Bushaltestelle (s. Abbildung 5.1), einen parkenden LKW und eine Baustelle. Auf der Gegenseite befanden sich entgegenkommende Fahrzeuge. Das Fahrverhalten des autonomen Fahrzeugs wurde vor der Studie aufgenommen und jeder Proband:in vorgespielt.

Während der Studie trugen die Proband:innen ein Microsoft 2 Smartband, um die Herzfrequenz und Interbeat Interval (IBI) mit einer Frequenz von 10 Hz aufzuzeichnen [Beggiato et al., 2018]. Das Interbeat Interval bezeichnet den zeitlichen Abschnitt zwischen zwei aufeinanderfolgenden Herzschlägen und korreliert somit mit der Herzratenvariabilität, welche ein Indikator für Stress ist (s. 2.2). Zusätzlich hatten die Proband:innen einen Handregler (s. Abb. 5.1) um kontinuierlich Feedback über ihre subjektiv wahrgenommene Unsicherheit über die sichere Funktionalität des Fahrzeugs, übermitteln. Dieser Handregler kann kontinuierliche Werte zwischen 0 und 100 mit einer Frequenz von 60 Hz aufzeichnen [Hartwich et al., 2018]. Stärkere Druck entspricht größerer subjektiver Unsicherheit. Die Verwendung des Reglers wurde während einer Testfahrt vor dem Experiment geübt. Alle Proband:innen erhielten eine monetäre Belohnung für die Studienteilnahme.



Abbildung 5.1: **Links:** Probandin mit Handregler während einer Fahrsimulatorstudie [Trende et al., 2020]. **Rechts:** Beispiel für Überholsituation während des Experiments.

Für das hier präsentierte Modell haben wir uns auf die Überholsituationen im Fahrzenario konzentriert. Es wurden die Daten für jedes Überholmanöver und Teilnehmer:in extrahiert. Dies führte zu einem Datensatz mit 150.000 Datenpunkten pro

Feature. Die Handreglerwerte wurden mithilfe eines Schwellwerts von 10 binarisiert, um die Trainingslabels für den Klassifizierer zu generieren. Werte unter dem Schwellwert wurden als *sicher* und Werte darüber als *unsicher* gelabelt. Insgesamt ergibt sich so eine Klassenverteilung von etwa 3:1 (*sicher* : *unsicher*). Dies führt zu einer Baseline Accuracy von etwa 75% für ein binäres Klassifikationsmodell.

Die untersuchten Modelle unterscheiden sich jeweils in der Anzahl der verwendeten Feature (s. Abb. 5.2). Das erste Modell verwendet nur Kontextfeature, wie die Fahrzeuggeschwindigkeit, Beschleunigung und Zeit bis zur Kollision mit anderen Verkehrsteilnehmer:innen. Das zweite Modell verwendet zudem zwei psychophysiologische Feature: die Herzrate und das Interbeat Interval. Dem dritten Modell wurde ein Feature, welches wir als *Individuelle Neigung zur Unsicherheit* bezeichnen, hinzugefügt. Dieses Feature entspricht individuellen Unterschieden zwischen den Proband:innen bezüglich ihrer subjektiven Unsicherheit und Risikowahrnehmung während der Nutzung von autonomen Fahrzeugen. Der Wert basiert auf den Messdaten des Handreglers jeder Proband:in aus der zweiten Fahrt. Daten aus der zweiten Fahrt wurden nicht für den Trainingsprozess der Modelle verwendet. Hierbei wurde die Summe der Handreglermesswerte berechnet und in die drei Gruppen: niedrig, mittel und hoch, eingeteilt. Diese Werte können als die Wahrscheinlichkeit für eine niedrige, mittlere oder große Tendenz für subjektive Unsicherheit während der Fahrt im simulierten autonomen Fahrzeug gesehen werden.

Künstliche neuronale Netze (KNN) wurden als Modell für diese Anwendung gewählt. Die KNNs enthalten zwei Schichten mit je 30 ReLU Einheiten. Jedes Feature wurde vor dem Training normalisiert. Des Weiteren wurde eine 3-fold Kreuzvalidierung für den Trainingsprozess verwendet. Nach dem Training wurde eine Receiver-Operating-Characteristics und Precision-Recall Analyse für jedes Modell durchgeführt. Der optimale Klassifizierungsschwellwert wurde basierend auf den F1-Werten der Modelle gewählt. Die Accuracy, F1-Werte, Präzision, Recall/Wahr-Positiv Rate (TPR) und Wahr-Negativ Rate (TNR) wurden nach der Anwendung des optimalen Klassifizierungsschwellwertes berechnet.

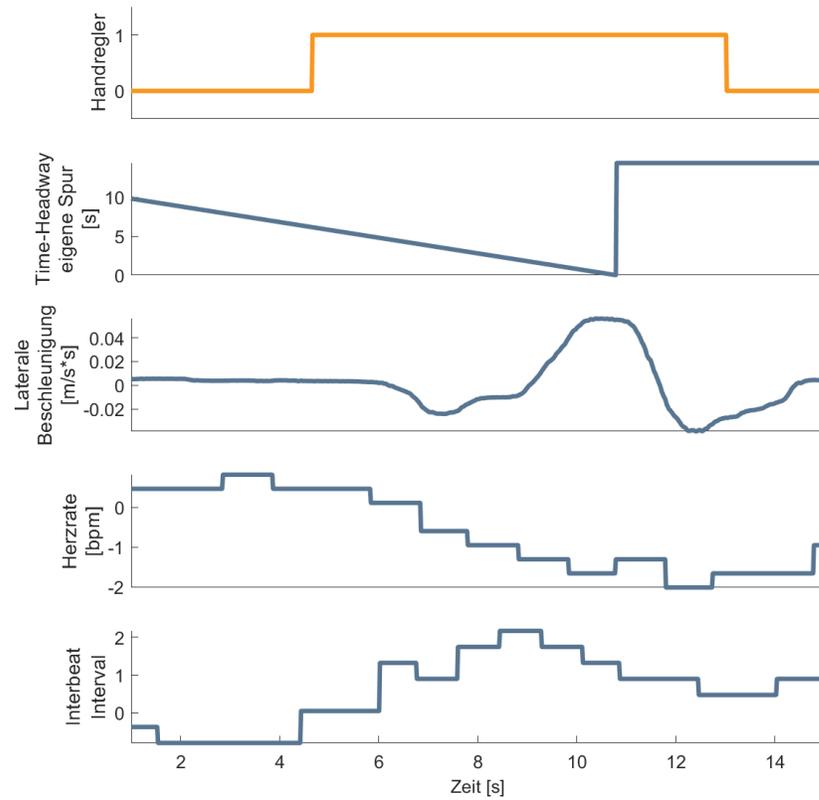


Abbildung 5.2: Zeitreihen für den subjektiven Unsicherheitswert und vier Features für ein Überholmanöver während des Experiments.

Feature	Modell 1	Modell 2	Modell 3
Abstand Ego Spur	✓	✓	✓
Abstand Gegenspur	✓	✓	✓
Geschwindigkeit	✓	✓	✓
Laterale Beschleunigung	✓	✓	✓
Longitudinale Beschleunigung	✓	✓	✓
Abstand zur Spurmitte	✓	✓	✓
Herzrate		✓	✓
Interbeat Intervall		✓	✓
Neigung zur individuellen Unsicherheit			✓

Tabelle 5.1: Übersicht über die verwendeten Feature der drei untersuchten Modelle.

5.3 Ergebnisse

Die besten Modelle wurden basierend auf den Precision-Recall Kurven und den entsprechenden F1-Werten ausgewählt (s. Abb. 5.3). Modell 1, welches nur Kontextfeature nutzt, hat eine durchschnittliche Accuracy von 75% und eine TPR von 73% (s. Tabelle 5.2). Gegeben die Verteilung der beiden Klassen bedeutet dies, dass das Modell nur so gut wie die Baseline ist. Durch das Hinzufügen der physiologischen Feature kann das Modell 2 eine mittlere Accuracy von 80% richtig klassifizieren und einen F1-Wert von 0.65 erreichen. Diese Verbesserung wird vor Allem durch eine höhere Präzision des Klassifizierers erreicht. Das beste Modell kann durch das Hinzufügen der Variable *Neigung zur individuelle Unsicherheit* erreicht werden. Es erreicht eine Accuracy von etwa 85%, einen F1-Wert von 0.72 und eine TNR von 87%.

Nachdem die Überholmanöver für alle Proband:innen gleich sind, lernt Modell 1 die Unsicherheit anhand von Kontextinformationen zu klassifizieren. Dies führt zu Falsch-Positiva, da der Schwellwert für subjektive Unsicherheit sich für jede Proband:in unterscheiden kann. Diese individuellen Unterschiede zwischen den Pro-

band:innen können so vom Modell nicht gelernt werden. In dieser Studie haben einige wenige Proband:innen den Handregler während eines Überholmanövers nicht gedrückt. Gründe hierfür könnten ein niedriger Schwellwert für die subjektive Unsicherheit bezüglich der präsentierten Automation oder ein Missverständnis hinsichtlich der Studieninstruktion. Modell 1 wird auch die Datenpunkte dieser Proband:innen fälschlicherweise als positiv, sprich unsicher, klassifizieren. In der Theorie sollte das Hinzufügen von physiologischen Variablen die Performance des Klassifizierers verbessern indem die TNR erhöht wird. Falls eine Proband:in eine Fahrsituation als nicht unsicher wahrnimmt, wird sich dies in den physiologischen Daten widerspiegeln. Dies scheint für Modell 2 zu funktionieren, da es mehr negative Datenpunkte korrekt klassifiziert und so die Anzahl der Falsch-Positiven reduziert. Modell 3 wurde zudem ein Indikator hinzugefügt, welcher angibt, ob eine Proband:in generell sensitiv für Unsicherheit beim autonomen Fahren ist. Dies reduziert die Anzahl der Falsch-Positiven weiter.

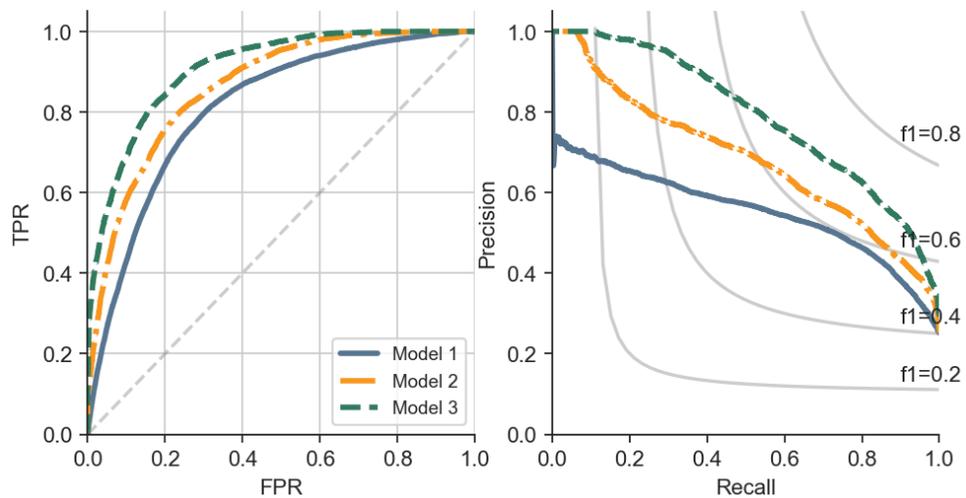


Abbildung 5.3: **Links:** Receiver-Operating-Characteristics (ROC) die drei untersuchten Modelle. **Rechts:** Precision-Recall Kurven für die gleichen Modelle. Modell 3 hat die beste Gesamtleistung, sowohl für die ROC Analyse als auch die Precision-Recall Kurven.

Metrik	Modell 1	Modell 2	Modell 3
Accuracy	0.75	0.80	0.85
Area-Under-Curve	0.80	0.87	0.92
Area Precision-Recall	0.74	0.82	0.89
Precision	0.49	0.58	0.67
Recall/True-positive rate	0.73	0.75	0.77
True-negative rate	0.75	0.82	0.87
F1 Score	0.59	0.65	0.72

Tabelle 5.2: Übersicht über die Resultate der Evaluation der Modelle. Modell 3 hat für alle Metriken die beste Performance.

5.4 Diskussion

In dieser Studie wurden drei verschiedene Modelle zur Klassifikation von subjektiver Unsicherheit in Überholmanövern beim simulierten autonomen Fahren untersucht. Das Modell, welches neben Kontext- und psychophysiologische Features noch die Variable *Neigung zur individuellen Unsicherheit* enthält, hat die besten Werte für alle Metriken erzielt. Es ergibt sich somit eine Accuracy von etwa 85% und eine $AUC = 0.92$. Diese Ergebnisse sind vergleichbar mit den Resultaten aus [Ping et al., 2018, Dommel et al., 2021]. Das Hinzufügen der Herzrate als psychophysiologischer Parameter ermöglicht es dem Modell die Wahr-Negativ-Rate zu erhöhen. Die Anzahl an falsch-positiven Klassifikationen kann durch das Hinzufügen des Parameters zur *Individuelle Neigung zur Unsicherheit* weiter reduziert werden und hilft somit, individuelle Unterschiede zwischen Proband:innen besser abzubilden.

Die experimentellen Daten unserer Studie zeigen, dass die subjektive Unsicherheit während der simulierten, autonomen Fahrt zwischen den Proband:innen stark variiert. Ein Modell, welches nur Kontextinformation verwendet, kann diese Variation zwischen Individuen nicht abbilden. Wir argumentieren, dass nutzerspezifische Information, wie die *Neigung zur individuellen Unsicherheit* oder demographische Informationen, wie Alter oder Geschlecht, berücksichtigt werden sollte. Diese Parameter

könnten mithilfe eines Fragebogens erhoben werden oder während der Nutzung eines autonomen Fahrzeuges gelernt werden.

5.5 Fazit

In dieser Studie wurden nur die Erkennung von Unsicherheit in Überholmanövern betrachtet. Es ist sinnvoll weitere, sicherheitskritische Manöver, zu betrachten. Beispiele hierfür wären Spurwechsel auf der Autobahn oder Abbiegesituationen mit entgegenkommenden Verkehr. Hierfür ist die Hinzunahme von weiteren Kontextvariablen notwendig. Außerdem können weitere psychophysiologische Messdaten erhoben und dem Modell hinzugefügt werden. Beispiele wären der Pupillendurchmesser, Hautleitfähigkeit oder Körperbewegung der Proband:innen [Beggiato et al., 2018]. Wie bereits oben erwähnt könnte das Hinzufügen von demographischen Daten die Klassifikation weiter verbessern [He et al., 2022]. Insbesondere Geschlecht und Alter könnten hier hilfreich sein [Antelmi et al., 2004]. Es muss außerdem erwähnt werden, dass die Kreuzvalidierung in der präsentierten Studie Daten von allen Proband:innen enthält. Es ist zu diesem Zeitpunkt nicht möglich ein Modell zu trainieren, welches verlässlich die Unsicherheit für eine Proband:in klassifizieren kann, deren Messdaten nicht im Trainingsprozess berücksichtigt wurden.

Des Weiteren können mehr zeitliche Informationen für die Modellierung verwendet werden. Es können Feature verwendet werden, welche zeitliche Information enthalten, wie zum Beispiel der gleitende Mittelwert eines Features. Eine weitere Möglichkeit ist die Nutzung von andere Netzwerkarchitekturen, wie Rekurrente Neuronale Netze oder Long Short-Term Memory Netze [Hochreiter and Schmidhuber, 1997], welche besonders gut für die Klassifikation von dynamischen Variablen geeignet sind. Weiterhin gilt zu beachten, dass eine Unsicherheitserkennung wie hier präsentiert das Tragen von Sensorik durch die Nutzer:in beziehungsweise die Erfassung von psychophysiologischen Parametern der Nutzer:in erfordert. Wie bereits in Kapitel 3 beschrieben, haben sich auch im Bereich der psychophysiologischen Datenaufzeichnung mehrere Studien mit der Nutzerakzeptanz sensorischer Geräte und insbesondere sogenannter *Wearables* befasst. [Kundinger et al., 2021] untersuchte die Akzeptanz von *Wearables* für die Erkennung von Ermüdung bei Fahrer:innen. Hierzu

fürten die Forscher:innen eine Fahrsimulatorstudie mit zwei Altersgruppen durch (20-25 und 65-70 Jahre). Die Technologieakzeptanz war für beide Gruppen hoch und die Nutzungsintensivierung eines solchen Systems war für die Gruppe der älteren Fahrer:innen höher. [Jacobs et al., 2019] untersuchte die Akzeptanz von Wearables von Arbeitnehmern. Wearables in Verbindung mit Nutzerzustandserkennung können nicht nur beim Autofahren, sondern auch am Arbeitsplatz vor sicherheitskritischen Situationen schützen. Ein wichtiges Ergebnis der Studie ist, dass die Akzeptanz von Wearables bei Arbeitnehmer:innen durch die freiwillige Nutzung oder durch Anreize erhöht werden kann. Es wurde zudem festgestellt, dass die Arbeitnehmer:innen davon überzeugt sein sollten, dass die Wearables einen positiven Effekt haben. Einer der wichtigsten Faktoren ist zudem, dass die Arbeitnehmer:innen bei der Einführung der Technologie eingebunden werden und dass der Zweck und die Funktionsweise der Systeme transparent dargestellt werden. Nur so kann Vertrauen und Akzeptanz in die Technologie geschaffen werden. Ein weiterer wichtiger Faktor sind Bedenken der Nutzer:innen bezüglich der Sicherheit und Verwendungszweck der aufgezeichneten Daten. Dieser Aspekt wurde bereits in vielen Studien, wie [Gao et al., 2015, Motti and Caine, 2015, Perez and Zeadally, 2017] untersucht. Die Studien präsentieren unterschiedliche Lösungen, wie Bedenken der Nutzer:innen bezüglich der Datennutzung und Sicherheit genommen werden können. Transparenz bei der Datennutzung und die aktive Freigabe beziehungsweise Einschränkung von bestimmten Daten durch die Nutzer:innen könnte helfen, die Akzeptanz der Datenaufzeichnung zu erhöhen. Eine Unsicherheitserkennung bereits in der Design- und Entwicklungsphase von HAV nützlich sein. Wie in der hier beschriebenen Studie können simulierte oder reale Fahrten mit HAV und gleichzeitiger Unsicherheitsmessung durchgeführt werden, um unkomfortable Situationen oder Fahrverhalten des HAV zu erkennen. Diese Erkenntnisse können anschließend genutzt werden, um Leitlinien für die Entwicklung von komfortablen und vertrauenswürdigen HAV zu schaffen. Eine Unsicherheitserkennung ermöglicht es, subjektive Unsicherheit während der Nutzung von HAV zu erkennen. Eine solche Erkennung kann genutzt werden, um Adaptionsstrategien zu initiieren, welche die Unsicherheit reduzieren und die Nutzung des Fahrzeugs komfortabler machen. Hierbei kann insbesondere der Fahrstil des HAV angepasst werden [Dettmann et al., 2021]. Es ist jedoch notwendig, dass eine geeignete Fahrstilparame-

trisierung mit entsprechenden Parameter-Vektoren beziehungsweise Parameterbereichen für unterschiedliche Fahrstilpräferenzen definiert werden. Im folgenden Kapitel wird näher auf das Thema Personalisierung des Fahrstil eines automatisierten Fahrzeugs eingegangen und die Ergebnisse einer Fahrsimulatorstudie zur Personalisierung von HAV präsentiert.

Kapitel 6

Fahrstilpersonalisierung von autonomen Fahrzeugen

6.1 Einleitung

Autofahren ist eine komplexe Aufgabe und Fahrer:innen haben unterschiedliche Präferenzen bezüglich ihres bevorzugten Fahrstils [Sagberg et al., 2015]. Ein Fahrstil besteht aus einer Menge an Parametern, welche die Fahrdynamik eines Fahrzeuges beschreibt. Beispiele hierfür sind die Geschwindigkeit, Beschleunigungen oder Abstände zu anderen Verkehrsteilnehmer:innen [Yusof et al., 2016]. Bisher wurden verschiedene Gruppen von Fahrer:innen und ihre präferierten Fahrstile in einer Vielzahl an Studien untersucht (z.B. [Yusof et al., 2016, Sagberg et al., 2015, Hartwich et al., 2018]). Der Standardfahrstil eines HAV für ein spezifisches Manöver kann für manche Personen unkomfortabel sein und dazu führen, dass sich diese Person nicht sicher bei der Nutzung des HAV fühlt. Studien suggerieren, dass die Proband:innen einen Fahrstil für HAV präferieren, welcher ähnlich zu ihrem eigenen ist. [Hartwich et al., 2018] hatten eine Fahrsimulatorstudie durchgeführt, um den Zusammenhang zwischen Fahrkomfort und Systemakzeptanz im Bezug auf die den Fahrstil des HAV und das Alter der Proband:innen zu untersuchen. Im ersten Teil der Studie fuhren die Proband:innen manuell. Anschließend wurde ihnen im Fahrsimulator ihre zuvor

aufgenommene Fahrt vorgespielt um die Fahrt in einem HAV zu simulieren. Die Ergebnisse der Studie suggerieren, dass ein HAV Fahrstil, welcher ähnlich zum eigenen Fahrstil ist sowohl Komfort, Fahrvergnügen und Systemakzeptanz für junge Fahrer:innen erhöht. [Sun et al., 2020b] führten eine Studie mit 36 Teilnehmer:innen durch, um Komfort und Vertrauen für manuelles, nicht-personalisiertes und personalisiertes automatisiertes Fahren zu untersuchen. Die Fahrzeuggeschwindigkeit und Beschleunigung wurde für das personalisierte automatisierte Fahren entsprechend dem manuellen Fahrstil der Proband:innen angepasst. Die Forscher:innen haben herausgefunden, dass die Proband:innen Vertrauen und Komfort für den personalisierten automatisierten Fahrstil am höchsten werteten.

Ein weitere wichtiger Aspekt für das Vertrauen in Automation ist, dass das Verhalten des Systems der Nutzer:in kommuniziert und somit bis zu einem bestimmten Grad transparent gemacht werden. Einige Wissenschaftler:innen haben bereits den Effekt und die Nützlichkeit von graphischen Nutzerschnittstellen zur Erhöhung von Vertrauen und Akzeptanz von HAV untersucht [Krefting et al., 2021, Beggiato et al., 2015, Hartwich et al., 2021]. Basierend auf einer Expertenfokusgruppe hat [Beggiato et al., 2015] herausgefunden, dass allem Transparenz und Vorhersagbarkeit von Systemhandlungen in HAV wichtig sind. Eine darauffolgende Fahrsimulatorstudie mit $N=20$ Teilnehmer:innen unterstützte diese Aussage. Die Studienergebnisse zeigten jedoch eine große Variabilität bezüglich der von den Proband:innen benötigten Informationen. Die Autor:innen erklärten diese Variabilität mit dem Vertrauen der Proband:innen in die Automation. Die Ergebnisse von [Hartwich et al., 2020] suggerieren, dass Nutzer:innen mit niedrigem Vertrauen in Automation einen höheren Bedarf an Informationen bezüglich des Systemstatus haben im Vergleich zu Nutzer:innen mit einem hohen Vertrauen in Automation. Die Forscher:innen führten eine Fahrsimulatorstudie in Kombination mit einem Interview durch, um Designvoraussetzungen für eine angenehme, automatisierte Fahrerfahrung zu sammeln. Insgesamt schlussfolgerten die Autor:innen, dass die Nutzer:innen nicht nur ausreichend Informationen benötigen, sondern auch einen komfortablen Fahrstil des autonomen Fahrzeuges für eine angenehme Fahrerfahrung.

Man kann annehmen, dass das Personalisieren von Fahrstilen eines HAV entsprechend der Nutzerpräferenzen eine valide Möglichkeit ist, um unkomfortable Situa-

tionen zu vermeiden und die Adoption der Technologie zu beschleunigen. Die Frage, wie ein HAV die Fahrstilpräferenzen einer Nutzer:in lernen soll, bleibt jedoch bestehen. Fahrstilparameter können unter Anderem durch Demonstration gelernt werden [Kuderer et al., 2015]. Anschließend kann sich das HAV entsprechend dieser Parameter anpassen, um einen Fahrstil ähnlich dem der Nutzer:in zu generieren. Leider erfordert dieser Ansatz das manuelle Fahren des Fahrzeuges bevor das HAV den präferierten Fahrstil replizieren kann. Dies erfordert Zeit und mehrere Wiederholungen von verschiedenen Fahrmanövern, um den optimalen Fahrstil zu erhalten. [Yusof et al., 2016] schlug vor, eine graphische Benutzeroberfläche zu verwenden, um den Fahrstil des HAV zu personalisieren. Diese Oberfläche erlaubt den Nutzer:innen den Fahrstil des HAV nach ihren Vorlieben zu gestalten. Ein ähnlicher Ansatz wurde in [Trende et al., 2019a] vorgestellt.

Hierzu wurde eine Fahrsimulatostudie durchgeführt, um zwei verschiedenen graphischen Mensch-Maschine Schnittstellen (HMIs) für die Personalisierung von Fahrstilparametern eines HAVs zu testen. Für diese Studie wurde sich auf Folgefah- und Überholmanöver auf Landstraßen konzentriert. Die HMIs erlaubten den Proband:innen verschiedene Fahrstilparameter bezogen auf diese Manöver in Realzeit während des Experiments zu ändern. Es sollte die Technologieakzeptanz solcher HMIs getestet werden. Des Weiteren sollte die Art und Weise untersucht werden, wie die Proband:innen mit den HMIs interagieren und ob es den Proband:innen möglich war einen passenden Fahrstil für ihre Präferenz zu finden.

6.2 Material und Methoden

In diesem Projekt wurde untersucht, ob Nutzer:innen die Möglichkeit haben wollen, den Fahrstil eines simulierten HAV mithilfe einer grafischen Mensch-Maschine Schnittstelle (HMI) anpassen zu können. Außerdem sollte analysiert werden wie die Proband:innen mit dem HMI interagieren und welche finalen Fahrstile sie für das HAV in der Studie einstellen. Generell besteht das Projekt aus drei Teilen: zuerst wurden initiale Fahrstile für das simulierte HAV mithilfe einer Fahrsimulatorstudie erhoben. Anschließend wurden zwei HMIs entworfen, welche im dritten Teil des Projektes mithilfe einer weiteren Fahrsimulatorstudie evaluiert wurden. Die HMIs

bieten den Proband:innen in der zweiten Fahrstudie die Möglichkeit, den Fahrstil eines simulierten HAVs anzupassen. Die HMIs unterscheiden sich in der Anzahl der anpassbaren Parameter und der Komplexität der angezeigten Information. Die Akzeptanz der HMIs wurde mithilfe von Fragebögen getestet.

6.2.1 Studie 1: Fahrstudie zur Fahrstiledefinition

Es wurde eine Fahrstudie mit $N = 25$ (33.6 Jahren ± 12.03 , 10 weiblich) Proband:innen durchgeführt, um initiale Fahrstile und die entsprechenden Fahrstilparameterbereiche zu ermitteln. Während einer 15 minütigen manuellen Fahrt haben die Proband:innen verschiedene Manöver, wie das Überholen eines vorrausfahrenden Fahrzeuges, durchgeführt. Für diese Manöver wurden Fahrstile und die assoziierten Parameter erhoben (s. Abb. 6.1). Für das Überholmanöver wurden die Geschwindigkeit, laterale Beschleunigung, Abstand zum vorrausfahrenden Fahrzeug und Abstand zum erneuten Spurwechsel nach dem Überholmanöver erhoben. Basierend auf den empirisch erhobenen Werten wurden die drei Fahrstile 'defensiv', 'entspannt' und 'sportlich' definiert. Zudem wurden die oberen und unteren Grenzen für die anpassbaren Parameterbereiche für die grafischen Mensch-Maschine Schnittstellen und das simulierte HAV definiert.

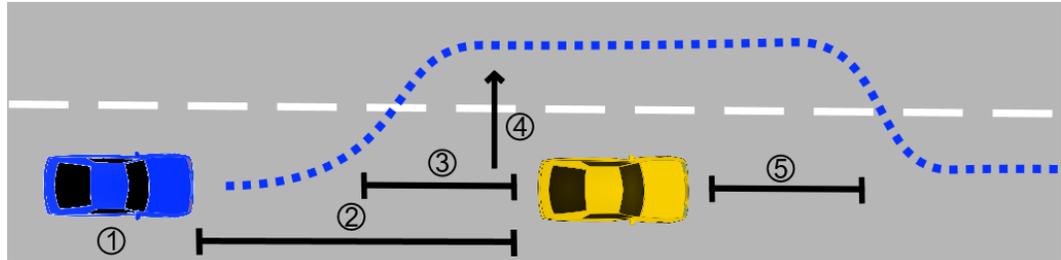


Abbildung 6.1: Übersicht über die Fahrstilparameter für das Überholmanöver: Geschwindigkeit (1), Abstand zum vorausfahrenden Fahrzeug (2), Abstand zum Initiieren des Überholmanövers (3), Parameter für die laterale Beschleunigung beim Überholen (4) und Abstand zum Spurwechsel nach dem Überholen (5).

6.2.2 Grafische Mensch-Maschine Schnittstellen

Zwei verschiedene grafische Mensch-Maschine Schnittstellen (HMIs) wurden für diese Studie von Ina Krefting entworfen und implementiert. Beide HMIs geben den Nutzer:innen die Möglichkeit, Fahrstilparameter des simulierten HAV zu ändern. Die beiden HMIs unterscheiden sich in der Anzahl an variablen Parametern (s. Abbildung 6.2) und wieviele Information angezeigt wird. Das simple HMI ermöglicht den Nutzer:innen die Geschwindigkeit, Abstand zum vorausfahrenden Fahrzeug (THW) und die laterale Beschleunigung für Überholmanöver zu variieren. Das komplexe HMI erlaubt den Nutzer:innen zudem die THW zur Initiierung des Überholmanövers und die Distanz zum erneuten Spurwechsel nach dem Überholen zu ändern. Beide HMIs zeigen eine simple Visualisierung des Überholmanövers, welche sich mit der Änderung der Parameter anpasst.



Abbildung 6.2: Simplex (links) und komplexes (rechts) HMI zur Fahrstilanpassung.

6.2.3 Studie 2: Fahrstudie zur Evaluation der HMIs zur Fahrstilanpassung

Die zweite Studie wurde im dynamischen Fahrstudie des DLR-SE durchgeführt (s. Abbildung 6.3). Der Fahrstudie basiert auf einem Golf 7 (2018) mit voll funktionsfähigem Interior und ist auf einem MOOG-Bewegungssystem (MB-E-6DOF/26/1800) montiert. Die Fahrstudie wird auf einer gekrümmten 210°-Leinwand dargestellt. Zwei Full-HD-Touchscreens befinden sich in der Mittelkonsole des Fahrzeugs und werden verwendet, um HMIs für Fahrstudie darzustellen. Die Fahrstudie wurde mithilfe der Fahrstudie-Software SILAB simuliert [Krüger et al., 2005].

Zu Beginn der Studie haben die Teilnehmer:innen einen ersten Fragebogen mit demographischen Fragen und Fragen zu ihrem subjektiven Fahrstil ausgefüllt. Es wurde

das Alter, Geschlecht und Fahrerfahrung der Proband:innen abgefragt. Die Fragen bezüglich des Fahrstils wurden [Taubman-Ben-Ari et al., 2004] entnommen und finden sich ebenfalls in Abschnitt 7.3.

Die erste Fahrt der Studie wurde gestartet nachdem die Proband:innen eine schriftliche Einführung zur Studie gelesen hatten. Entsprechend der Ergebnisse des Fahrstilfragebogens wurde ein vordefinierter Fahrstil für das HAV ausgewählt. Anschließend erlebten die Proband:innen eine fünfzehnminütige simulierte, automatisierte Landstraßenfahrt. Das Geschwindigkeitslimit variierte zwischen 100, 120 und 130 km/h. Dieses Geschwindigkeitslimit wurde den Proband:innen durch Verkehrszeichen und Informationen im HMI kommuniziert. Auf beiden Spuren der Landstraße fuhren verschiedene andere Fahrzeuge, sodass das simulierte HAV mehrere Überholmanöver durchführte. Während der Fahrt hatten die Proband:innen die Möglichkeit, das Fahrverhalten des simulierten HAV mithilfe des HMIs zu ändern. Der einzige Unterschied während der zweiten Fahrt der Studie war, dass den Nutzer:innen das komplexe HMI angezeigt wurde. Nach den zwei Fahrten wurde den Teilnehmer:innen ein zweiter Fragebogen mit Fragen zur Nutzerakzeptanz der HMIs vorgelegt. Um die beiden HMIs zu evaluieren wurde den Nutzer:innen die Fragen aus [Cho et al., 2017] präsentiert. Diese Fragen wurden ausgewählt um die Technologieakzeptanz für autonome Fahrzeuge zu evaluieren. Hierbei wurden 24 Fragen ausgewählt und in die folgenden acht Faktoren gruppiert: *Performance Expectancy*, *Effort Expectancy*, *Self-Efficacy*, *Perceived Safety*, *Anxiety*, *Trust*, *Affective Satisfaction* and *Behavior Intention*. Zusätzlich haben die Nutzer:innen noch sechs qualitative Fragen bezüglich Präferenzen und Anmerkungen zu den HMIs beantwortet.



Abbildung 6.3: Dynamischer Fahr Simulator des DLR-SE.

6.3 Ergebnisse

6.3.1 Studie 1: Fahrsimulatorstudie zur Fahrstiledefinition

Tabelle 1 zeigt alle Parameter der drei verschiedenen Fahrstile und die entsprechenden unteren und oberen Grenzen für die HMIs. Geschwindigkeitswerte wurden nicht definiert, da das Geschwindigkeitslimit im Experiment zwischen 100, 120 und 130 km/h variiert. Somit konnten die Proband:innen die Geschwindigkeit zwischen 100 und 130 km/h variieren.

Parameter	Defensiv	Entspannt	Sportlich
THW [s]	2.00	1.60	1.00
Parameter für maximale laterale Beschleunigung	1.25	1.40	1.67
THW Beginn Überholmanöver [s]	3.50	2.80	2.00
Einscherabstand nach Überholmanöver [m]	30.0	20.0	10.0

Tabelle 6.1: Überblick über die definierten Fahrstilparameter für das simulierte HAV. Geschwindigkeitswerte wurden nicht definiert, da das Geschwindigkeitslimit im Experiment zwischen 100, 120 und 130 km/h variiert.

6.3.2 Studie 2: Fahrsimulatorstudie zur Evaluation der Fahrstil HMIs

11 Proband:innen (26.92 Jahre \pm 8.43; sieben weiblich, vier männlich) nahmen an der Studie zur Evaluation der Fahrstil HMIs teil. Vor dem Experiment füllten die Proband:innen einen Fragebogen mit Fragen zu ihrem subjektiven Fahrstil aus. Die Ergebnisse finden sich in 6.2. Der mittlere Werte für die Fragen bezüglich des *entspannten* Fahrstils waren signifikant höher als Fragen für die anderen Fahrstile.

MDSI Fahrstilfaktoren	Mittelwert	Standardabweichung
Langsam und defensiv	1.99	0.37
Entspannt	4,83	0.27
Sportlich und riskant	1.64	0.49

Tabelle 6.2: Ergebnisse des MDSI Fragebogens zu subjektiven Fahrstilfaktoren

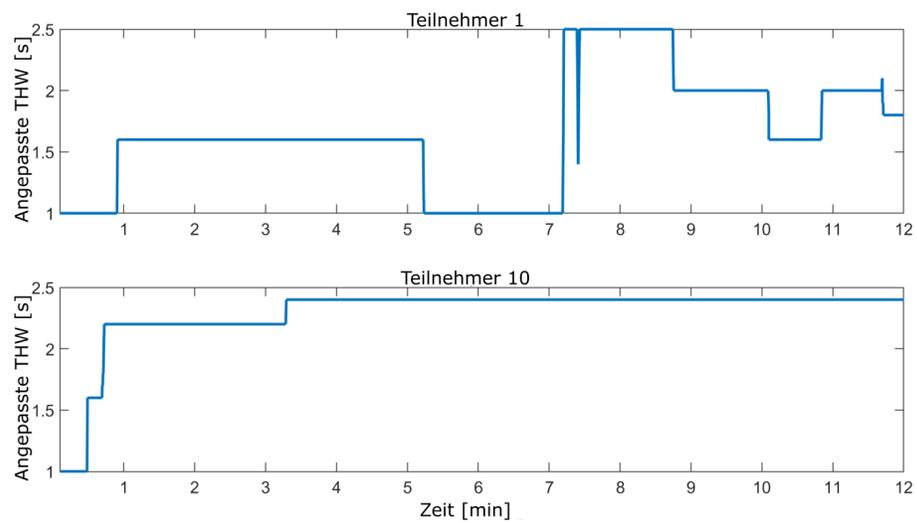


Abbildung 6.4: Zwei Beispiele für die Anpassungen der Parameter während des Experiments. In beiden Abbildungen haben die Proband:innen den Abstand des HAV zum vorrausfahrenden Fahrzeuges geändert. Proband:in 1 (oben) hat während dem Experiment viele Änderungen durchgeführt. Proband:in 10 (unten) hingegen hat nur in den ersten 3,5 Minuten Änderungen an der THW vorgenommen.

Zu Beginn des Fahrsimulatorexperiments hatten die Proband:innen die Möglichkeit einen der vordefinierten Fahrstile zu wählen. Jede der elf Proband:innen hat den *entspannten* Fahrstil gewählt. Dies stimmt mit den Ergebnissen des Fahrstilfragebogens überein. Hierbei hatte der *entspannte* Fahrstil den höchsten mittleren Wert (s. Tabelle 6.2). Während der Fahrsimulation wurden alle Interaktionen der

Proband:innen mit den HMIs aufgezeichnet. Beispiele für die Anpassungen des Abstandes zu vorrausfahrenden Fahrzeugen finden sich in Abbildung 6.4. Proband:in 1 (oben) hat während dem Experiment viele Änderungen durchgeführt. Proband:in 10 (unten) hingegen hat nur in den ersten 3.5 Minuten Änderungen an der THW vorgenommen. Tabelle 6.3 zeigt die Ergebnisse beider HMIs und aller anpassbaren Parameter. Der Mittelwert und die Standardabweichung wurden für jeden Parameter berechnet. Im simplen HMI konnten die Parameter *Abstand zum Ausscheren* und *Abstand zum Einscheren* nicht geändert werden. Außerdem wurden die prozentualen Änderungen bezüglich der initialen Parameterwerte des *entspannten* Fahrstils berechnet. Insgesamt haben die Proband:innen die THW, die laterale Beschleunigung und den Abstand zum Ausscheren erhöht. Nur der Einscherabstand nach dem Überholmanöver wurde reduziert. Die Änderungen bewegen sich im Bereich 12% und 25% im Vergleich zu den initialen Parameterwerten.

Parameter	HMI	Mittelwert	Standardabweichung	Prozentuale Änderung
Time Headway (THW) [s]	Simpel	1.80	0.37	+12.25%
	Komplex	1.60	0.38	0.00%
Beschleunigungsparameter	Simpel	1.72	0.08	+22.86%
	Komplex	1.67	0.10	+19.29%
THW Initiierung	Simpel	2.80	0.00	
	Komplex	3.40	0.62	+21.43%
Einscherabstand nach Überholmanöver	Simpel	20.00	0.00	
	Komplex	15.00	15.00	-25%

Tabelle 6.3: Übersicht über die finalen Parameterwerte, welche durch die Proband:innen während des Experimentes eingestellt wurden.

Der zweite Schritt der Analyse der Nutzerinteraktionen mit den HMIs war die

Berechnung der Anzahl der Änderungen, welche die Proband:innen während des Experimentes vorgenommen haben. Tabelle 6.3 zeigt die mittlere Anzahl an Parameteränderungen der Proband:innen nach HMI an. Alle Parameter wurden im Mittel etwa vier bis fünf Mal geändert.

Außerdem wurde die Zeit berechnet bis die Proband:innen die letzten Parameteränderungen durchgeführt haben. Die letzten Änderungen wurden zwischen sechs und neun Minuten im Experiment durchgeführt. Sowohl die Anzahl der Änderungen als auch die Zeit bis zur letzten Änderung war niedriger für das komplexe HMI.

Parameter	Anzahl der Änderungen		Zeit bis zur letzten Änderung	
	Simplex HMI	Komplex HMI	Simplex HMI	Komplex HMI
THW	5.00 ± 3.28	4.55 ± 3.58	8.46 ± 3.77	7.06 ± 4.42
Beschleunigungsparameter	5.55 ± 3.06	4.36 ± 2.64	9.26 ± 3.20	5.85 ± 4.18
THW Initiierung [s]			4.82 ± 2.41	6.68 ± 4.12
Einscherabstand nach Überholmanöver			4.18 ± 2.52	6.62 ± 3.58

Tabelle 6.4: Übersicht über die Mittelwerte und Standardabweichungen für die mittlere Anzahl an Parameteränderungen und Zeit bis die letzte Änderungen durchgeführt wurde.

Der letzte Teil der Analyse der HMI Interaktionen war die Anzahl der Proband:innen zu berechnen, welche einen finalen Satz an Fahrstilparametern während der Studie eingestellt haben. Für alle Fahrstilparameter wurde die Zeit bis zur letzten Änderung berechnet und hieraus den Mittelwert gebildet. Es wurde entschieden, dass eine Nutzer:in einen finalen Parametersatz gefunden hat, falls diese mittlere Zeit weniger als die Dauer des Experiments minus zwei Minuten war. Sowohl für das simple

als auch das komplexe HMI haben acht der elf Teilnehmer:innen einen finalen Satz an Parametern eingestellt. Bei beiden HMIs haben jeweils die Teilnehmer:innen fünf und sechs bis zum Ende des Experimentes Änderungen an den Parametern vorgenommen. Abschließend wurde die Interaktion mit dem Geschwindigkeitsparameter des HAV betrachtet. Insgesamt haben die Teilnehmer:innen den Geschwindigkeitsparameter öfters während des Experimentes geändert, da sich auch das Geschwindigkeitslimit öfters geändert hat. Im Mittel wurde der Geschwindigkeitsparameter 8.64 ± 2.96 Mal für das simple und 9.27 ± 2.14 Mal für das komplexe HMI geändert. Abbildung 6.5 und Tabelle 6.5 zeigen die Interaktionen mit dem Geschwindigkeitsparameter nach HMI und Geschwindigkeitslimit.

Geschwindigkeitslimit [km/h]	HMI	Angepasste Ge- schwindigkeit [km/h]	Standard- abweichung
100	Simpel	101.10	2.07
	Komplex	102.26	2.75
120	Simpel	119.14	5.42
	Komplex	120.78	3.36
130	Simpel	127.10	6.50
	Komplex	128.23	1.93

Tabelle 6.5: Übersicht über Mittelwerte und Standardabweichungen für die gewählte Geschwindigkeiten für die drei unterschiedlichen Geschwindigkeitslimits.

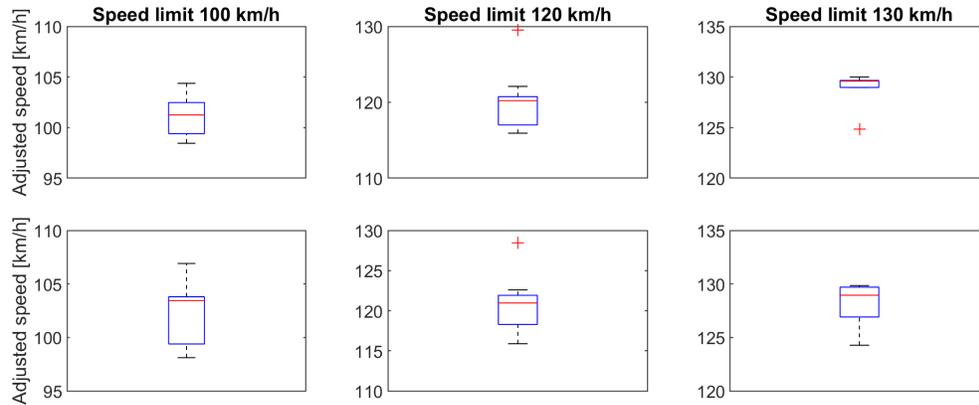


Abbildung 6.5: Boxplots für die angepassten Geschwindigkeiten des HAV für das simple (oben) und komplexe (unten) HMI and die entsprechenden Geschwindigkeitslimits im Experiment.

6.3.3 Studie 2: Fahrsimulatorstudie zur Evaluation der Fahrstil HMIs - Fragebogenergebnisse

Nach der Fahrsimulatorstudie füllten die Proband:innen einen Fragebogen mit Fragen zu ihren Präferenzen bezüglich des HMI Designs aus. Allgemein haben die Proband:innen die Frage *Unterstützen die HMIs die Fahrer:in bei der Nutzung des Fahrzeuges?* mit einer durchschnittlichen Wertung von 4.38 aus 5 Punkten bewertet. Des Weiteren haben zehn der elf Proband:innen das komplexe HMI bevorzugt. Nur eine Person hatte keine Präferenz bezüglich des HMI Designs. Die Proband:innen füllten außerdem noch einen Technologieakzeptanzfragebogen nach [Cho et al., 2017] aus. Die mittleren Werte für alle Fragen (s. Appendix 7.3) und Faktoren (s. Tabelle 6.6 und Abbildung 6.6) wurden zudem berechnet. Fragen bezüglich der Leistungserwartung wurden für das komplexe HMI höher bewertet (3.85 vs. 4.38). Dies gilt auch für die Nutzungsintention (3.28 vs. 4.00). Des Weiteren wurden Vertrauen und affektive Zufriedenheit von den Proband:Innen für das komplexe HMI leicht höher bewertet (4.15 vs. 4.49 und 3.80 vs. 4.07). Die restlichen Faktoren, mit Ausnahme der Anstrengungserwartung wurden für beide HMIs in etwa gleich bewertet.

Faktor	Simple HMI	komplexes HMI
Performance Expectancy (PE)	3.85	4.38
Effort Expectancy (EE)	4.23	3.82
Self-Efficacy (SE)	4.54	4.59
Perceived Safety (PS)	3.18	3.18
Anxiety (AX)	2.02	1.95
Trust (T)	4.15	4.49
Affective Satisfaction (AS)	3.80	4.07
Behavior Intention (BI)	3.29	4.00

Tabelle 6.6: Übersicht über Mittelwerte und Standardabweichungen für die gewählte Geschwindigkeiten für die drei unterschiedlichen Geschwindigkeitslimits.

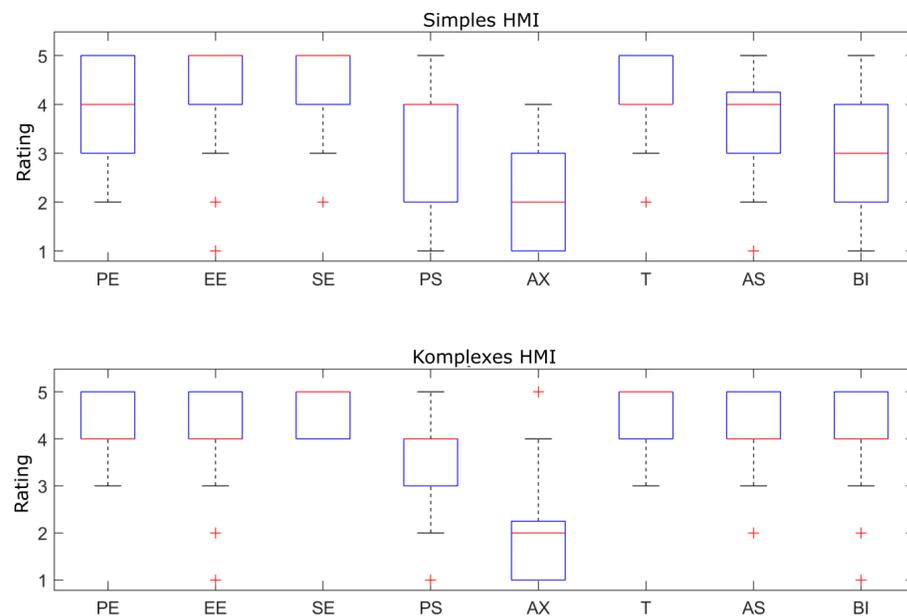


Abbildung 6.6: Boxplots für das simple (oben) und komplexe (unten) HMI und den Ergebnissen der Nutzerakzeptanzfaktoren

6.4 Diskussion

In diesem Projekt wurden Präferenzen und Interaktionen bezüglich der Personalisierung von HAV Fahrstilen untersucht. Hierfür wurde eine Fahrsimulatorstudie durchgeführt, um die Interaktionen von Proband:innen mit zwei unterschiedlichen HMIs zur Personalisierung des Fahrstils eines simulierten HAVs zu untersuchen. Des Weiteren haben die Proband:innen Fragebögen bezüglich ihres subjektiven Fahrstils und Technologieakzeptanz des HMIs ausgefüllt.

Zuerst wurde die finalen Parameterwerte berechnet, welche die Proband:innen während des Experimentes eingestellt haben und hieraus die mittleren Unterschiede zu den Initialparametern berechnet. Die Proband:innen haben die THW, die THW zur Initiierung des Überholmanövers und die Distanz zum Spurwechsel nach dem Überholmanöver erhöht. Diese Änderungen suggerieren, dass die Proband:innen nicht nur mit den initialen Parametern unzufrieden waren, sondern auch, dass sie eine defensivere Wahl an Werten bevorzugen. Interessanterweise wurde die laterale Beschleunigung während des Überholmanövers erhöht, wobei hierbei argumentiert werden kann, dass eine höhere laterale Beschleunigung zu einer schnelleren Durchführung des Überholmanövers führt.

Als Nächstes wurde die Anzahl an Parameteränderungen, welche jeweils von den Proband:innen durchgeführt wurden gezählt und hieraus die Mittelwerte und Standardabweichungen berechnet 6.4. Sowohl für das simple als auch das komplexe HMI scheinen acht der elf Teilnehmer:innen einen passenden Satz an Parametern vor Ende des Experimentes gefunden zu haben. Der Geschwindigkeitsparameter wurde am häufigsten geändert. Dies war zu erwarten nachdem das Geschwindigkeitslimit zwischen 100, 120 und 130 km/h variierte. Trotz des gegebenen Geschwindigkeitslimits haben die Proband:innen Änderungen am Geschwindigkeitsparameter vorgenommen. Die mittleren Geschwindigkeitswerte für alle Teilnehmer:innen waren nah an den gegebenen Geschwindigkeitslimits (s. 6.5). Grund hierfür kann sein, dass die Teilnehmer:innen während der Fahrt beobachtet wurden und somit die Geschwindigkeit nicht signifikant höher als das Geschwindigkeitslimit setzen wollten.

Nach dem Experiment haben die Proband:innen einen Fragebogen mit allgemeinen quantitativen und qualitativen Fragen bezüglich ihrer Präferenz der getesteten HMIs

ausgefüllt. Außerdem haben sie 24 Fragen zu acht verschiedenen Faktoren bezüglich der Technologieakzeptanz beantwortet. Alle quantitativen Fragen wurden auf einer 5 Punkte Skala bewertet. Die Teilnehmer:innen wurden gefragt, ob ein HMI zur Personalisierung von HAV Fahrstilen dem Fahrer helfen würde. Diese Frage wurde durchschnittlich mit 4.38 aus 5 Punkten bewertet. Dem Nutzer mehr Informationen und Freiraum während der Mensch-Maschine Kooperation zu geben kann die Nutzerakzeptanz und Vertrauen erhöhen [Chiou and Lee, 2021]. Die Ergebnisse des Nutzerakzeptanzfragebogens ergänzen sich mit den Ergebnissen ähnlicher Studien hinsichtlich der Erkenntnisse, dass die Nutzung von HMIs in HAVs die Nutzerakzeptanz und Vertrauen erhöhen kann [Krefting et al., 2021, Beggiato et al., 2015, Hartwich et al., 2021].

Im Bezug auf den Vergleich zwischen den beiden HMIs wurden alle positiven Faktoren mit einem mittleren Wert von 3.86 für das simple HMI und 4.07 für das komplexe HMI bewertet. Dieses Ergebnis unterstützt die Schlussfolgerung, dass die Teilnehmer:innen beide HMIs als nützlich und hilfreich empfunden haben. Die Fragen bezüglich der *Performance Expectancy* (3.85 vs. 4.38) und *Behavior Intention* (3.28 vs. 4.00) wurden für das komplexe HMI höher gewertet. Die Bewertung für die *Performance Expectancy* suggerieren, dass die Teilnehmer:innen ein komplexeres HMI wegen der umfangreicheren Möglichkeiten präferieren würden. Diese Möglichkeiten könnten den Nutzer:innen eines HAV helfen, den idealen Satz an Fahrstilparametern zu finden. Die Ergebnisse für *Anxiety* (2.02 und 1.95) legen nahe, dass die Teilnehmer:innen sicher bei der Nutzung der HMIs waren. Dies wird außerdem durch den mittleren Wert für *Trust* (3.80 und 4.07) suggeriert. Insgesamt legen die Bewertungen für *Trust*, *Perceived Safety* und *Anxiety* nahe, dass die Teilnehmer:innen die HMIs verlässlich und sicher während des Experimentes empfanden. Die Faktoren *Anxiety*, *Self-Efficacy* und *Perceived Safety* wurden für beide HMIs fast gleich bewertet. Nur der Faktor *Effort Expectancy* wurde für das simple HMI höher bewertet. Dies war zu erwarten nachdem das simple HMI weniger variable Parameter bietet und somit die Nutzung einfacher ist.

6.5 Fazit

Die hier präsentierte Studie hat einige Limitierungen: zum einen ist die Stichprobengröße von elf Teilnehmer:innen eher gering. Vergleichbare Studien zu Fahrstilen wie [Hartwich et al., 2019] oder Datensätze [Xu et al., 2022, Jensen et al., 2020, Bock et al., 2020] haben eine deutlich größere Stichprobengröße, um Forschungsfragen bezüglich Fahrstilen und Fahrstilparametern zu untersuchen. Eine größere Stichprobengröße kann nicht nur zu signifikanteren Ergebnissen, sondern auch zu einer größeren Variabilität an untersuchten Fahrstilen führen. Eine weitere Limitierung war die Länge des Experimentes. Auch wenn acht der elf Teilnehmer:innen keine Änderungen an den Fahrstilparametern mehr in den letzten zwei Minuten des Experimente gemacht haben kann es sein, dass das Experiment nicht lang genug war, um den perfekten Satz an Fahrstilparametern zu finden. Des Weiteren wurden nur die Manöver Folgefahren und Überholen untersucht. Die Komplexität des Verkehrs und die große Anzahl an Manövern, welche im Verkehr durchgeführt werden, bedeutet, dass viele Parameter für den optimalen Fahrstil angepasst werden müssen. Dies kann Nutzer:innen schnell überfordern. Besonders Nutzer:innen mit niedriger Technikaffinität haben höchstwahrscheinlich kein Interesse daran, eine große Anzahl an Fahrstilparameter anzupassen. Dies bedeutet, dass ein passender voreingestellter Fahrstil die beste Option sein kann. Dieser Fahrstil kann mithilfe eines kurzen Fragebogens erhoben werden.

Eine schnelle und reibungslose Einführung von HAVs ist wünschenswert. Um dies zu erreichen sollten sich Nutzer:innen sicher und komfortabel bei der Nutzung von HAV fühlen. Den Nutzer:innen die Möglichkeit zur Anpassung des HAV Fahrstils zu geben, kann eine Möglichkeit sein diese Einführung zu beschleunigen und Nutzerakzeptanz zu schaffen.

Kapitel 7

Fazit, Limitierungen & Ausblick

7.1 Fazit

Human-Cyber-Physical Systeme werden in den nächsten Jahren noch weitreichender und tiefer in der Gesellschaft verankert sein. Hierbei ist vor Allem eine immer weitreichendere Automation der Cyber-Physical Komponenten angestrebt. Es ist jedoch äußerst wichtig, dass der Mensch bei dieser immer komplexeren Automation nicht aus dem Auge verloren wird. Dabei ist es wichtig, dass der Mensch weiterhin Teil des Gesamtsystems ist und die Möglichkeit hat, die Entscheidungen beziehungsweise Handlungen der Automation nachzuvollziehen und im Notfall auch überschreiben kann. Dies bedeutet, dass Forscher:innen, Entwickler:innen und Designer:innen solcher HCPS entsprechende Anforderungen an die Konzeption und Entwicklung solcher Systeme formulieren müssen, damit diese von den relevanten Stakeholdern umgesetzt werden können.

Viele Konsortien aus Forscher:innen haben bereits Referenzarchitekturen für solche HCPS vorgestellt (z.B. Abbildung 1.2, [Sowe et al., 2019, Sun et al., 2020a, Zhou et al., 2019]). Ein gemeinsamer Nenner dieser Architekturen ist eine Komponente, welche menschliches Verhalten und Zustände modellieren kann. Diese Komponente ist wichtig, damit das HCPS das menschliche Verhalten antizipieren und die Zustände des Menschen erkennen kann. Dies ermöglicht es einem solchen System, dass es

seine Kontrollstrategie beziehungsweise Verhalten daran anpassen kann. So können sicherheitskritische Situationen, welche durch negativen Menschzustände oder Verhalten verursacht werden, im Vornherein verhindert beziehungsweise der Schaden minimiert werden.

In dieser Arbeit wurde das (autonome) Fahren von Straßenfahrzeugen als Anwendungsfall für HCPS gewählt. In Deutschland gab es im Jahre 2022 48.5 Millionen Autos¹ und in ganz Europa etwa 250 Millionen. Die Transition zu autonomen Fahren ist eine der bedeutungsvollsten Schritte in der Entwicklung von HCPS. Dieser Übergang erfordert nicht nur, dass die Automationsfunktionen sicher funktionieren, sondern auch, dass die Bedürfnisse der Nutzer:innen beim Design und Funktionsweise dieser Fahrzeuge berücksichtigt werden damit negative Nutzerzustände, wie Frust oder Unsicherheit bei der Verwendung der autonomen Fahrzeuge verhindert werden können.

In Kapitel 5 wurde ein Modell zur Erkennung von subjektiver Unsicherheit im simulierten autonomen Fahren präsentiert. Hierbei wurden neben Fahrdynamikdaten und Kontextinformationen über die Verkehrssituation auch die Herzrate als psychophysiologische Messgröße verwendet. Es konnte gezeigt werden, dass sich die Leistung des Modells durch die Hinzunahme dieser Messgrößen bereits verbessern lässt. Im Experiment erlebte jede Proband:in die gleichen Verkehrssituationen, wodurch ein Modell, welches nur auf Kontextdaten basiert keine individuellen Unterschiede zwischen ProbandInnen abbilden kann. Psychophysiologische Messgrößen wie die Herzrate oder elektrodermale Aktivität können solche Unterschiede zwischen Proband:innen abbilden. Die Hinzunahme eines weiteren Parameters, welcher mit der allgemeinen Tendenz zur Unsicherheit im autonomen Fahren korreliert, konnte die Leistung des Modells weiter verbessern.

Eine Möglichkeit, um Diskomfort bei der Nutzung von HAV zu minimieren, kann die Anpassung des Fahrstils an die Präferenzen der Nutzer:in sein. Die Ergebnisse aus Kapitel 6 zeigen, dass die Proband:innen eine positive Nutzerakzeptanz für grafische Benutzerschnittstellen zur Personalisierung eines simulierten HAV haben. Auch [Chiou and Lee, 2021] kommt zu dem Schluss, dass mehr Informationen und

¹<https://de.statista.com/statistik/daten/studie/12131/umfrage/pkw-bestand-in-deutschland/>

Freiraum während der Mensch-Maschine Kooperation die Nutzerakzeptanz und Vertrauen erhöhen kann.

In Kapitel 3 wurden die Ergebnisse zweier Modelle zur Erkennung der Abbiegeintention von Proband:innen dargestellt. Hierbei konnte gezeigt werden, dass analog zu Kapitel 5 die Integration von Daten aus verschiedenen Datenquellen die Leistung eines solchen Modelles verbessern kann. Im ersten Teil des Kapitels wurde ein allgemeines Modell basierend auf dem Gesamtdatensatz und allen Proband:innen präsentiert. Die Ergebnisse zeigen, dass die Integration von demographische Daten, wie dem Geschlecht und subjektive Einschätzungen zum Fahrstil, die Leistung des Modelles verbessern kann. Im zweiten Teil des Kapitels wurde der Fokus auf individuelle Modelle für jede Proband:in gelegt. Es wurde gezeigt, dass die Integration von neurophysiologischen Messdaten mithilfe eines fNIRS Systems und Kontextdaten, die Leistung der trainierten Modelle verbessern kann.

Solche Modelle könnten Komponenten von fortgeschrittenen Fahrassistenzsystemen sein, welche die Intention der Nutzer:innen antizipiert und bei sicherheitskritischen Situationen interveniert. Mögliche Interventionen wären eine Warnung der Nutzer:in durch Mensch-Maschine Schnittstellen oder das Eingreifen in die Fahrdynamik, wie eine Notbremsung, durch das Fahrassistenzsystem (s. 7.1).

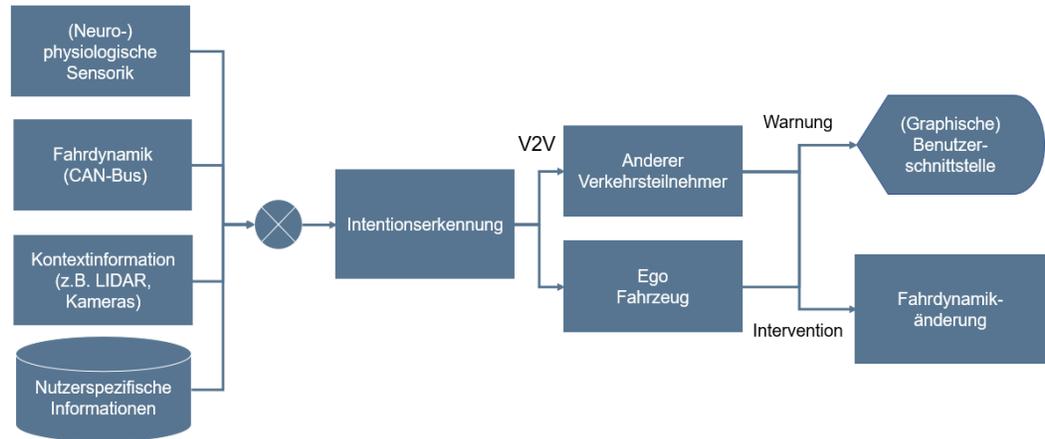


Abbildung 7.1: Flowchart für situationsbasierte Anpassung des Egofahrzeugs oder eines weiteren Fahrzeuges mithilfe von V2V Technologie.

Der Übergang von manuellen Fahrzeugen zu komplett selbstfahrenden Fahrzeugen wird nicht instantan geschehen. Es kommt somit über eine längere Zeitspanne zu einem hybriden Verkehr mit manuell gesteuerten und autonomen Fahrzeugen im Straßenverkehr. Es ist somit wichtig zu verstehen, welches mentale Modell Menschen bezüglich der Interaktion mit autonomen Fahrzeugen haben. Entsprechend beschäftigt sich Kapitel 4 mit zwei Studien, welche Unterschiede bei der Interaktion von Fahrer:innen mit hochautonomen Fahrzeugen in Abbiegesituationen untersuchten. Die Ergebnisse der Studien legen nahe, dass Menschen das angeblich defensive und sichere Fahrverhalten von autonomen Fahrzeugen ausnutzen könnten, um sich in zeitkritischen Situationen einen Vorteil zu verschaffen. Dieser *Missbrauch der Automation* kann jedoch zu sicherheitskritischen Situationen führen. Entsprechend sollten diese Erkenntnisse beim Design von autonomen Fahrzeugen und deren Planungsalgorithmen berücksichtigt werden. Die offensichtlichste Vorgehensweise wäre, eine möglichst defensive Fahrweise bei der Interaktion mit Menschen anzustreben.

7.2 Limitierungen

Die hier präsentierten Arbeiten haben einige nennenswerte Limitierungen, welche in zukünftigen Arbeiten adressiert werden sollten. Zum einen war die Anzahl der Teilnehmer:innen in den durchgeführten Studien eher gering. Es nahmen zwischen 12 und 50 Teilnehmer:innen an den Fahrsimulatorstudien teil. Besonders im Kontext der Verkehrsforschung ist dies eine eher geringe Stichprobengröße für die Modellierung von Fahrverhalten. In Studien zur Untersuchung des Abbiegeverhaltens, wie zum Beispiel [Ragland et al., 2005], werden Abbiegeentscheidungen von oft hundert Individuen mithilfe von Videomaterial an realen Kreuzungen analysiert. Somit ergibt sich eine deutlich heterogene Verteilung bezüglich Charakteristika der Fahrer:innen. Fahrsimulatorstudien haben jedoch den Vorteil, dass alle Proband:innen die vom Experimentator entworfenen Versuchsbedingungen exakt gleich durchführen und mehrmals wiederholen können. Dies erhöht die statistische Validität der Ergebnisse.

Ein weiterer Nachteil der hier präsentierten Modelle ist, dass psychophysiologische und neurophysiologische Messwerte schwer generalisierbar sind. Dies zeigt sich deutlich in der niedrigeren Leistung des fNIRS Modells aus Abschnitt 3.4, welches auf den Daten aller Proband:innen trainiert wurde. Die Schwierigkeiten bei der Generalisierbarkeit von psychophysiologischen Messverfahren wurden für den gleichen Datensatz aus 5 von [Niermann et al., 2021] gezeigt. Hierbei war die Leistung von einem generellen Modell zur Unsicherheitserkennung deutlich schlechter als individuell, trainierte Modelle für einzelne Proband:innen. Im Idealfall wird die Forschung im Bereich der Nutzerzustands- und Intensionserkennung in den kommenden Jahren Fortschritte bezüglich der Generalisierbarkeit der Methoden machen. Alternativ kann ein HCPS auch für jede individuelle Nutzer:in angepasst werden. So kann ein zukünftiges autonomes Fahrzeug mit einem allgemeinen *Basis-Nutzermodell* ausgeliefert werden, welches auf einem sehr heterogenen Datensatz trainiert wurde. Anschließend wird dieses Modell in der frühen Phase der Nutzung auf die einzelne Nutzer:in angepasst. Eine weitere mögliche Verbesserung wäre vordefinierte Nutzermodelle für verschiedene demographische Nutzergruppen zu erstellen, wobei zu Beginn der Nutzung des HCPS das ähnlichste Modell für die Nutzer:in ausgewählt und anschließend iterativ

verbessert wird.

Eine weitere Limitierung von psycho- und neurophysiologischen Messwerte ist, dass sie auch von Faktoren, welche nicht durch die experimentellen Bedingungen kontrolliert werden, verändert werden können. Betrachtet man zum Beispiel eine Realfahrtstudie zur Messung von Stress mithilfe von psychophysiologischen Messverfahren. Erscheint beispielsweise ein Rettungsfahrzeug mit angeschalteter Sirene, kann dies bei einer Fahrer:in Stress und Unsicherheit erzeugen. Diese Unsicherheit kann jedoch ohne die Kontextinformation über die aktuelle Verkehrssituation und insbesondere das Rettungsfahrzeug nicht korrekt zugeordnet werden. Es ist also wichtig, dass einem Modell zur Interpretation dieser Messwerte soviel Kontextinformation wie möglich zur Verfügung steht, um Ambiguitäten bezüglich der Ursache für einen Nutzerzustand klar zu differenzieren. Hierbei könnte auch die Kombination von Modellen aus dem Bereich des maschinellen Lernens und kognitive Modelle, wie ACT-R [Anderson et al., 1997] oder CASCaS [Lüdtke et al., 2010] helfen. Eine weitere Hürde für die Integration von Menschmodellen in Kombination mit psycho- oder neurophysiologischen Messverfahren können Datenschutzbedenken und Skepsis gegenüber solcher Messverfahren sein. Um die erforderliche Akzeptanz zu schaffen ist es hierfür wichtig, dass der Nutzen der Systeme und die Verwendung der Daten für die Menschen ersichtlich sind.

7.3 Ausblick

Mit Fortschritt in Forschung und Infrastruktur werden HCPS immer mehr in unsere Gesellschaft und Leben Einzug nehmen. Wie bereits in 7.1 beschrieben ist es notwendig, dass die Rolle des Menschen in diesen HCPS beim Design und Entwicklung eben solcher beachtet wird. Dabei ist in unseren Augen insbesondere die Kooperation und Interaktion zwischen dem Menschen und den CPS wichtig, um eine sichere und vertrauensvolle Zusammenarbeit zu ermöglichen. Hierfür ist die Kooperation von Stakeholdern aus verschiedenen Bereichen relevant. Die Tragweite dieses Unterfangens erfordert, dass sowohl Wissenschaft, Industrie, Politik und Legislative zusammenarbeiten. Im Bereich der Wissenschaft ist die Kooperation von Wissenschaftler:innen aus einer Vielzahl von Forschungsbereichen erforderlich. Hierbei sind

Forschungsgebieten, wie die Informatik oder Ingenieurwissenschaften, welche sich mit den technischen Aspekten der HCPS beschäftigen, notwendig. Zudem benötigt es die Expertise von Psycholog:innen und Datenwissenschaftler:innen, welche die Validität der Menschmodelle und Modelle der Kooperation zwischen Menschen und cyber-physischen Systemen schaffen und validieren. Zuletzt ist es wichtig, dass HCPS auch in einem makroskopischen Kontext betrachtet werden. Hierbei sind insbesondere Sozial- und Geisteswissenschaftler:innen notwendig, welche die gesetzlichen, gesellschaftlichen und moralischen Aspekte der Integration von HCPS in die Gesellschaft untersuchen.

Die hier präsentierten Arbeiten fallen allen voran in den zweiten Bereich, welcher sich mit der Modellierung des Menschen beim Fahren eines Fahrzeuges beziehungsweise bei der Nutzung und Interaktion von HAV befasst. Es zeigt sich, dass insbesondere bei den technologischen Grundlagen und der Interpretation von neuro-beziehungsweise psychophysiologischen Messverfahren noch weiterer technologischer und wissenschaftlicher Fortschritt notwendig ist. Insbesondere neurophysiologische Messverfahren haben zum jetzigen Zeitpunkt nicht die technologischen Voraussetzungen, um eine praktikable Nutzung im Straßenverkehr zu gewährleisten. Es müssen portable Messgeräte entwickelt werden, welche eine angemessene temporale und räumliche Auflösung beim Messen haben. Des Weiteren sind Fortschritte bei der Interpretation der Messdaten notwendig. Durch die Komplexität, die das Fahren im Straßenverkehr mit sich bringt, kann es zu Ambiguitäten kommen. Dies erschwert eine korrekte Zustands- und Intentionserkennung. Die in dieser Arbeit präsentierten Modelle des maschinellen Lernens können die Nutzerzustände beziehungsweise Intentionen sehr gut erkennen. Die Kontextinformation hilft nicht nur bei der Erkennung, sondern kann auch helfen mögliche Ambiguitäten aufzulösen.

Insgesamt lässt sich sagen, dass die Gesellschaft von der Einführung und Entwicklung von weiteren und fortgeschritteneren HCPS profitieren kann. Damit diese Einführung gelingt, müssen die System zuverlässig und sicher funktionieren, sodass die Menschen sie akzeptieren und ihnen vertrauen können. Die Rolle des Menschen in diesen HCPS sollte ein wichtiger, wenn nicht sogar der wichtigste Aspekt beim Design und der Entwicklung dieser Systeme sein. Nur so lassen sich HCPS entwerfen, welche eine produktive und risikoarme Kooperation ermöglichen.

Referenzen

- [Ahn et al., 2016] Ahn, S., Nguyen, T., Jang, H., Kim, J. G., and Jun, S. C. (2016). Exploring neuro-physiological correlates of drivers' mental fatigue caused by sleep deprivation using simultaneous eeg, ecg, and fnirs data. *Frontiers in human neuroscience*, 10:219.
- [Anderson et al., 1997] Anderson, J. R., Matessa, M., and Lebiere, C. (1997). Act-r: A theory of higher level cognition and its relation to visual attention. *Human-Computer Interaction*, 12(4):439–462.
- [Andreassi, 2010] Andreassi, J. L. (2010). *Psychophysiology: Human behavior and physiological response*. Psychology Press.
- [Antelmi et al., 2004] Antelmi, I., De Paula, R. S., Shinzato, A. R., Peres, C. A., Mansur, A. J., and Grupi, C. J. (2004). Influence of age, gender, body mass index, and functional capacity on heart rate variability in a cohort of subjects without heart disease. *The American journal of cardiology*, 93(3):381–385.
- [Automotive, 2022] Automotive, I. (2022). Carmaker.
- [Ba et al., 2017] Ba, Y., Zhang, W., Wang, Q., Zhou, R., and Ren, C. (2017). Crash prediction with behavioral and physiological features for advanced vehicle collision avoidance system. *Transportation Research Part C: Emerging Technologies*, 74:22–33.
- [Bucks et al., 2000] Bucks, R. W., Navidzadeh, H. T., and Xu, X. (2000). Cardio-respiratory indices of mental workload during simulated air traffic control. In *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, volume 44, pages 89–92. SAGE Publications Sage CA: Los Angeles, CA.
- [Basu et al., 2017] Basu, C., Yang, Q., Hungerman, D., Singhal, M., and Dragan, A. D. (2017). Do you want your autonomous car to drive like you? In *Proceedings of the 2017 ACM/IEEE International Conference on Human-Robot Interaction*, pages 417–425.

- [Beggiato et al., 2018] Beggiato, M., Hartwich, F., and Krems, J. (2018). Using smartbands, pupillometry and body motion to detect discomfort in automated driving. *Frontiers in human neuroscience*, 12:338.
- [Beggiato et al., 2019] Beggiato, M., Hartwich, F., and Krems, J. (2019). Physiological correlates of discomfort in automated driving. *Transportation research part F: traffic psychology and behaviour*, 66:445–458.
- [Beggiato et al., 2015] Beggiato, M., Hartwich, F., Schleinitz, K., Krems, J., Other- sen, I., and Petermann-Stock, I. (2015). What would drivers like to know during automated driving? information needs at different levels of automation. In *7. Tagung Fahrerassistenzsysteme*.
- [Berndt et al., 2008] Berndt, H., Emmert, J., and Dietmayer, K. (2008). Continuous driver intention recognition with hidden markov models. In *2008 11th International IEEE Conference on Intelligent Transportation Systems*, pages 1189–1194. IEEE.
- [Bianco et al., 2019] Bianco, S., Napoletano, P., and Schettini, R. (2019). Multi- modal car driver stress recognition. In *Proceedings of the 13th EAI International Conference on Pervasive Computing Technologies for Healthcare*, pages 302–307.
- [Biebl, 2021] Biebl, Bianca und Bengler, K. (2021). I spy with my mental eye— analyzing compensatory scanning in drivers with homonymous visual field loss. In *Congress of the International Ergonomics Association*, pages 552–559. Springer.
- [Blain-Moraes et al., 2012] Blain-Moraes, S., Schaff, R., Gruis, K. L., Huggins, J. E., and Wren, P. A. (2012). Barriers to and mediators of brain–computer interface user acceptance: focus group findings. *Ergonomics*, 55(5):516–525.
- [Blana, 1996] Blana, E. (1996). Driving simulator validation studies: A literature review.
- [Bock et al., 2020] Bock, J., Krajewski, R., Moers, T., Runde, S., Vater, L., and Eckstein, L. (2020). The ind dataset: A drone dataset of naturalistic road user trajectories at german intersections. In *2020 IEEE Intelligent Vehicles Symposium (IV)*, pages 1929–1934. IEEE.
- [Bottom and Ashworth, 1978] Bottom, C. and Ashworth, R. (1978). Factors affecting the variability of driver gap-acceptance behaviour. *Ergonomics*, 21(9):721–734.
- [Boucsein and Backs, 2000] Boucsein, W. and Backs, R. W. (2000). Engineering psychophysiology as a discipline: Historical and theoretical aspects. *Engineering psychophysiology: Issues and applications*, pages 3–30.

- [Branzi et al., 2017] Branzi, V., Domenichini, L., and La Torre, F. (2017). Drivers' speed behaviour in real and simulated urban roads—a validation study. *Transportation research part F: traffic psychology and behaviour*, 49:1–17.
- [Brigadoi et al., 2014] Brigadoi, S., Ceccherini, L., Cutini, S., Scarpa, F., Scatturin, P., Selb, J., Gagnon, L., Boas, D. A., and Cooper, R. J. (2014). Motion artifacts in functional near-infrared spectroscopy: a comparison of motion correction techniques applied to real cognitive data. *Neuroimage*, 85:181–191.
- [Casson, 2019] Casson, A. J. (2019). Wearable eeg and beyond. *Biomedical engineering letters*, 9(1):53–71.
- [Chiou and Lee, 2021] Chiou, E. K. and Lee, J. D. (2021). Trusting automation: Designing for responsivity and resilience. *Human factors*, page 00187208211009995.
- [Cho et al., 2017] Cho, Y., Park, J., Park, S., and Jung, E. S. (2017). Technology acceptance modeling based on user experience for autonomous vehicles. *Journal of the Ergonomics Society of Korea*, 36(2):87–108.
- [Choi, 2010] Choi, E.-H. (2010). Crash factors in intersection-related crashes: An on-scene perspective.
- [Chollet, 2021] Chollet, F. (2021). *Deep learning with Python*. Simon and Schuster.
- [Chung et al., 2019] Chung, W.-Y., Chong, T.-W., and Lee, B.-G. (2019). Methods to detect and reduce driver stress: a review. *International journal of automotive technology*, 20(5):1051–1063.
- [Commons, 2009] Commons, W. (2009). Polar rs400 heart rate monitor.jpg.
- [Commons, 2014] Commons, W. (2014). Tobii glasses 2 eye tracker wearable system tobii i.jpg.
- [Commons, 2019] Commons, W. (2019). Blonde fnirs lady.
- [Commons, 2021] Commons, W. (2021). Example of a deep neural network.
- [Cowley et al., 2016] Cowley, B. U., Filetti, M., Lukander, K., Torniainen, J., Helenius, A., Ahonen, L., Barral Mery de Bellegarde, O., Kosunen, I. J., Valtonen, T., Huotilainen, M. J., et al. (2016). The psychophysiology primer: a guide to methods and a broad review with a focus on human-computer interaction. *Foundations and Trends in Human-Computer Interaction*.
- [Cunningham and Regan, 2015] Cunningham, M. and Regan, M. A. (2015). Autonomous vehicles: human factors issues and future research. In *Proceedings of the 2015 Australasian Road safety conference*, volume 14.

- [Damm et al., 2019] Damm, W., Fränze, M., Lüdtkke, A., Rieger, J. W., Trende, A., and Unni, A. (2019). Integrating neurophysiological sensors and driver models for safe and performant automated vehicle control in mixed traffic. In *2019 IEEE Intelligent Vehicles Symposium (IV)*, pages 82–89. IEEE.
- [Darzentas et al., 1980] Darzentas, J., McDowell, M., and Cooper, D. F. (1980). Minimum acceptable gaps and conflict involvement in a simple crossing manoeuvre. *Traffic Engineering & Control*, 21(2).
- [Dawson et al., 2017] Dawson, M. E., Schell, A. M., and Filion, D. L. (2017). The electrodermal system.
- [De Beaucorps et al., 2017] De Beaucorps, P., Streubel, T., Verroust-Blondet, A., Nashashibi, F., Bradai, B., and Resende, P. (2017). Decision-making for automated vehicles at intersections adapting human-like behavior. In *2017 IEEE Intelligent Vehicles Symposium (IV)*, pages 212–217. IEEE.
- [De Winter et al., 2007] De Winter, J., Wieringa, P., Dankelman, J., Mulder, M., Van Paassen, M., and De Groot, S. (2007). Driving simulator fidelity and training effectiveness. In *Proceedings of the 26th European annual conference on human decision making and manual control, Lyngby, Denmark*, pages 20–22. Citeseer.
- [Delpy and Cope, 1997] Delpy, D. and Cope, M. (1997). Quantification in tissue near-infrared spectroscopy. *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 352(1354):649–659.
- [Dettmann et al., 2021] Dettmann, A., Hartwich, F., Roßner, P., Beggiato, M., Felbel, K., Krems, J., and Bullinger, A. C. (2021). Comfort or not? automated driving style and user characteristics causing human discomfort in automated driving. *International Journal of Human-Computer Interaction*, 37(4):331–339.
- [Dijksterhuis et al., 2011] Dijksterhuis, C., Brookhuis, K. A., and De Waard, D. (2011). Effects of steering demand on lane keeping behaviour, self-reports, and physiology. a simulator study. *Accident Analysis & Prevention*, 43(3):1074–1081.
- [Dillen et al., 2020] Dillen, N., Ilievski, M., Law, E., Nacke, L. E., Czarnecki, K., and Schneider, O. (2020). Keep calm and ride along: Passenger comfort and anxiety as physiological responses to autonomous driving styles. In *Proceedings of the 2020 CHI conference on human factors in computing systems*, pages 1–13.
- [Dommel et al., 2021] Dommel, P., Pichler, A., and Beggiato, M. (2021). Comparison of a logistic and svm model to detect discomfort in automated driving. In *International Conference on Intelligent Human Systems Integration*, pages 44–49. Springer.

- [Dosovitskiy et al., 2017] Dosovitskiy, A., Ros, G., Codevilla, F., Lopez, A., and Koltun, V. (2017). Carla: An open urban driving simulator. In *Conference on robot learning*, pages 1–16. PMLR.
- [Drewitz et al., 2020] Drewitz, U., Ihme, K., Bahnmüller, C., Fleischer, T., La, H., Pape, A.-A., Gräfin, D., Niermann, D., and Trende, A. (2020). Towards user-focused vehicle automation: the architectural approach of the autoakzept project. In *International Conference on Human-Computer Interaction*, pages 15–30. Springer.
- [Drewitz et al., 2019] Drewitz, U., Ihme, K., Oehl, M., Schrödel, F., Voßwinkel, R., Hartwich, F., Schmidt, C., Pape, A.-A., Fleischer, T., Cornelsen, S., et al. (2019). Automation ohne unsicherheit: vorstellung des förderprojekts autoakzept zur erhöhung der akzeptanz automatisierten fahrens.
- [Feng et al., 2018] Feng, C., Wanyan, X., Yang, K., Zhuang, D., and Wu, X. (2018). A comprehensive prediction and evaluation method of pilot workload. *Technology and health care*, 26(S1):65–78.
- [Ferrari et al., 1980] Ferrari, M., Giannini, I., Carpi, A., Fasella, P., Fieschi, C., and Zanette, E. (1980). Non invasive infrared monitoring of tissue oxygenation and circulatory parameters. In *XII World Congress of Angiology, Athens, September*, pages 7–12.
- [Fisher, 1936] Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 7(2):179–188.
- [Fitzpatrick, 1991] Fitzpatrick, K. (1991). Gaps accepted at stop-controlled intersections. *Transportation Research Record*, 1303(11):103–112.
- [Fricker et al., 1991] Fricker, J. D., Gutierrez, M., and Moffett, D. (1991). Gap acceptance and wait time at unsignalized intersections. In *Intersections Without Traffic Signals II*, pages 297–307. Springer.
- [Galvani, 2019] Galvani, M. (2019). History and future of driver assistance. *IEEE Instrumentation & Measurement Magazine*, 22(1):11–16.
- [Gao et al., 2015] Gao, Y., Li, H., and Luo, Y. (2015). An empirical study of wearable technology acceptance in healthcare. *Industrial Management & Data Systems*.
- [Gentner and Classen, 2009] Gentner, R. and Classen, J. (2009). Development and evaluation of a low-cost sensor glove for assessment of human finger movements in neurophysiological settings. *Journal of neuroscience methods*, 178(1):138–147.

- [Gerstenberger, 2015] Gerstenberger, M. (2015). *Unfallgeschehen an Knotenpunkten: Grundlagenuntersuchung zu Ursachen und Ansätzen zur Verbesserung durch Assistenz*. PhD thesis, München, Technische Universität München, Diss., 2015.
- [Gori et al., 2016] Gori, M., Cappagli, G., Tonelli, A., Baud-Bovy, G., and Finocchietti, S. (2016). Devices for visually impaired people: High technological devices with low user acceptance and no adaptability for children. *Neuroscience & Behavioral Reviews*, 69:79–88.
- [Green, 1994] Green, P. (1994). Driver workload as a function of road geometry: A pilot experiment. Technical report.
- [Haghani et al., 2021] Haghani, M., Bliemer, M. C., Farooq, B., Kim, I., Li, Z., Oh, C., Shahhoseini, Z., and MacDougall, H. (2021). Applications of brain imaging methods in driving behaviour research. *Accident Analysis & Prevention*, 154:106093.
- [Hahnloser et al., 2000] Hahnloser, R. H., Sarpeshkar, R., Mahowald, M. A., Douglas, R. J., and Seung, H. S. (2000). Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. *nature*, 405(6789):947–951.
- [Hajinoroozi et al., 2016] Hajinoroozi, M., Mao, Z., Jung, T.-P., Lin, C.-T., and Huang, Y. (2016). EEG-based prediction of driver’s cognitive performance by deep convolutional neural network. *Signal Processing: Image Communication*, 47:549–555.
- [Hamed et al., 1997] Hamed, M., Easa, S., and Batayneh, R. (1997). Disaggregate gap-acceptance model for unsignalized t-intersections. *Journal of transportation engineering*, 123(1):36–42.
- [Harding et al., 2014] Harding, J., Powell, G., Yoon, R., Fikentscher, J., Doyle, C., Sade, D., Lukuc, M., Simons, J., Wang, J., et al. (2014). Vehicle-to-vehicle communications: readiness of v2v technology for application. Technical report, United States. National Highway Traffic Safety Administration.
- [Hartwich et al., 2018] Hartwich, F., Beggiato, M., and Krems, J. F. (2018). Driving comfort, enjoyment and acceptance of automated driving—effects of drivers’ age and driving style familiarity. *Ergonomics*, 61(8):1017–1032.
- [Hartwich et al., 2021] Hartwich, F., Hollander, C., Johannmeyer, D., and Krems, J. F. (2021). Improving passenger experience and trust in automated vehicles through user-adaptive hmis:“the more the better” does not apply to everyone. *Frontiers in Human Dynamics*, page 38.

- [Hartwich et al., 2020] Hartwich, F., Schmidt, C., Gräfin, D., and Krems, J. F. (2020). In the passenger seat: Differences in the perception of human vs. automated vehicle control and resulting hmi demands of users. In *International Conference on Human-Computer Interaction*, pages 31–45. Springer.
- [Hartwich et al., 2019] Hartwich, F., Witzlack, C., Beggiato, M., and Krems, J. F. (2019). The first impression counts—a combined driving simulator and test track study on the development of trust and acceptance of highly automated driving. *Transportation research part F: traffic psychology and behaviour*, 65:522–535.
- [Hastie et al., 2009] Hastie, T., Tibshirani, R., and Friedman, J. (2009). An introduction to statistical learning.
- [Haufe et al., 2014] Haufe, S., Kim, J.-W., Kim, I.-H., Sonnleitner, A., Schrauf, M., Curio, G., and Blankertz, B. (2014). Electrophysiology-based detection of emergency braking intention in real-world driving. *Journal of neural engineering*, 11(5):056011.
- [Haufe et al., 2011] Haufe, S., Treder, M. S., Gugler, M. F., Sagebaum, M., Curio, G., and Blankertz, B. (2011). Eeg potentials predict upcoming emergency brakings during simulated driving. *Journal of neural engineering*, 8(5):056001.
- [He et al., 2022] He, X., Stapel, J., Wang, M., and Happee, R. (2022). Modelling perceived risk and trust in driving automation reacting to merging and braking vehicles. *Transportation research part F: traffic psychology and behaviour*, 86:178–195.
- [Healey and Picard, 2000] Healey, J. and Picard, R. (2000). Smartcar: detecting driver stress. In *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*, volume 4, pages 218–221. IEEE.
- [Healey and Picard, 2005] Healey, J. A. and Picard, R. W. (2005). Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on intelligent transportation systems*, 6(2):156–166.
- [Herff et al., 2017] Herff, C., Putze, F., and Schultz, T. (2017). Evaluating fnirs-based workload discrimination in a realistic driving scenario. In *The First Biannual Neuroadaptive Technology Conference*, page 69.
- [Hernandez et al., 2011] Hernandez, J., Morris, R. R., and Picard, R. W. (2011). Call center stress recognition with person-specific models. In *International Conference on Affective Computing and Intelligent Interaction*, pages 125–134. Springer.

- [Hernández et al., 2018] Hernández, L. G., Mozos, O. M., Ferrández, J. M., and Antelis, J. M. (2018). Eeg-based detection of braking intention under different car driving conditions. *Frontiers in neuroinformatics*, 12:29.
- [Hochreiter and Schmidhuber, 1997] Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8):1735–1780.
- [Jacobs et al., 2019] Jacobs, J. V., Hettinger, L. J., Huang, Y.-H., Jeffries, S., Lesch, M. F., Simmons, L. A., Verma, S. K., and Willetts, J. L. (2019). Employee acceptance of wearable technology in the workplace. *Applied ergonomics*, 78:148–156.
- [Jebelli et al., 2018] Jebelli, H., Hwang, S., and Lee, S. (2018). Eeg-based workers’ stress recognition at construction sites. *Automation in Construction*, 93:315–324.
- [Jensen et al., 2020] Jensen, M. B., Møgelmoose, A., and Moeslund, T. B. (2020). Presenting the multi-view traffic intersection dataset (mtid): A detailed traffic-surveillance dataset. In *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*, pages 1–6. IEEE.
- [Jöbsis, 1977] Jöbsis, F. F. (1977). Noninvasive, infrared monitoring of cerebral and myocardial oxygen sufficiency and circulatory parameters. *Science*, 198(4323):1264–1267.
- [Kaptein et al., 1996] Kaptein, N. A., Theeuwes, J., and Van Der Horst, R. (1996). Driving simulator validity: Some considerations. *Transportation research record*, 1550(1):30–36.
- [Kennedy et al., 2008] Kennedy, G. E., Judd, T. S., Churchward, A., Gray, K., and Krause, K.-L. (2008). First year students’ experiences with technology: Are they really digital natives? *Australasian journal of educational technology*, 24(1).
- [Khan and Hong, 2015] Khan, M. J. and Hong, K.-S. (2015). Passive bci based on drowsiness detection: an fnirs study. *Biomedical optics express*, 6(10):4063–4078.
- [Kim et al., 2014] Kim, I.-H., Kim, J.-W., Haufe, S., and Lee, S.-W. (2014). Detection of braking intention in diverse situations during simulated driving based on eeg feature combination. *Journal of neural engineering*, 12(1):016001.
- [Kingma and Ba, 2014] Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [Klingelschmitt et al., 2014] Klingelschmitt, S., Platho, M., Groß, H.-M., Willert, V., and Eggert, J. (2014). Combining behavior and situation information for reliably estimating multiple intentions. In *2014 IEEE Intelligent Vehicles Symposium Proceedings*, pages 388–393. IEEE.

- [Krefting et al., 2021] Krefting, I., Trende, A., Unni, A., Rieger, J., Luedtke, A., and Fränzle, M. (2021). Evaluation of graphical human-machine interfaces for turning manoeuvres in automated vehicles. In *13th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, pages 77–80.
- [Krüger et al., 2005] Krüger, H.-P., Grein, M., Kaussner, A., Mark, C., et al. (2005). Silab—a task-oriented driving simulation. In *Driving Simulation Conference*.
- [Kuderer et al., 2015] Kuderer, M., Gulati, S., and Burgard, W. (2015). Learning driving styles for autonomous vehicles from demonstration. In *2015 IEEE International Conference on Robotics and Automation (ICRA)*, pages 2641–2646. IEEE.
- [Kundinger et al., 2021] Kundinger, T., Riener, A., and Bhat, R. (2021). Performance and acceptance evaluation of a driver drowsiness detection system based on smart wearables. In *13th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, pages 49–58.
- [Kurpiers et al., 2020] Kurpiers, C., Biebl, B., Mejia Hernandez, J., and Raisch, F. (2020). Mode awareness and automated driving—what is it and how can it be measured? *Information*, 11(5):277.
- [Lin et al., 2018] Lin, J., Liu, S., Huang, G., Zhang, Z., and Huang, K. (2018). The recognition of driving action based on eeg signals using wavelet-csp algorithm. In *2018 IEEE 23rd international conference on digital signal processing (DSP)*, pages 1–5. IEEE.
- [Liu and Salvucci, 2001] Liu, A. and Salvucci, D. (2001). Modeling and prediction of human driver behavior. In *Intl. Conference on HCI*, pages 1479–1483.
- [Liu et al., 2020] Liu, P., Du, Y., Wang, L., and Da Young, J. (2020). Ready to bully automated vehicles on public roads? *Accident Analysis & Prevention*, 137:105457.
- [Liu and Ozguner, 2007] Liu, Y. and Ozguner, U. (2007). Human driver model and driver decision making for intersection driving. In *2007 IEEE intelligent vehicles symposium*, pages 642–647. IEEE.
- [Lüdtke et al., 2010] Lüdtke, A., Osterloh, J.-P., Mioch, T., Rister, F., and Looije, R. (2010). Cognitive modelling of pilot errors and error recovery in flight management tasks. In *Human Error, Safety and Systems Development*, pages 54–67. Springer.
- [Lundberg and Lee, 2017] Lundberg, S. M. and Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.

- [Luzuriaga et al., 2021] Luzuriaga, M., Trunzer, S., and Schick, B. (2021). A missing link between fidelity and realism: an experts' assessment of an advanced motion-based driving simulator. *International Journal of Vehicle Systems Modelling and Testing*, 15(2-3):141–163.
- [Masters and Schulte, 2022] Masters, M. and Schulte, A. (2022). Physiological sensor fusion for real-time pilot workload prediction in a helicopter simulator. In *AIAA SCITECH 2022 Forum*, page 2344.
- [McKenna et al., 1991] McKenna, F. P., Stanier, R. A., and Lewis, C. (1991). Factors underlying illusory self-assessment of driving skill in males and females. *Accident Analysis & Prevention*, 23(1):45–52.
- [Mehler et al., 2012] Mehler, B., Reimer, B., and Coughlin, J. F. (2012). Sensitivity of physiological measures for detecting systematic variations in cognitive demand from a working memory task: an on-road study across three age groups. *Human factors*, 54(3):396–412.
- [Millard-Ball, 2018] Millard-Ball, A. (2018). Pedestrians, autonomous vehicles, and cities. *Journal of planning education and research*, 38(1):6–12.
- [Morales-Alvarez et al., 2020] Morales-Alvarez, W., Sipele, O., Léberon, R., Tadjine, H. H., and Olaverri-Monreal, C. (2020). Automated driving: A literature review of the take over request in conditional automation. *Electronics*, 9(12):2087.
- [Morris et al., 2017] Morris, D. M., Erno, J. M., and Pilcher, J. J. (2017). Electrodermal response and automation trust during simulated self-driving car use. In *Proceedings of the human factors and ergonomics society annual meeting*, volume 61, pages 1759–1762. SAGE Publications Sage CA: Los Angeles, CA.
- [Motti and Caine, 2015] Motti, V. G. and Caine, K. (2015). Users' privacy concerns about wearables. In *International Conference on Financial Cryptography and Data Security*, pages 231–244. Springer.
- [Nature Editorial, 2022] Nature Editorial (2022). Safe driving cars. *Nature Machine Intelligence*, 4(2):95–96.
- [Niermann et al., 2021] Niermann, D., Trende, A., Ihme, K., Drewitz, U., Hollander, C., and Hartwich, F. (2021). An integrated model for user state detection of subjective discomfort in autonomous vehicles. *Vehicles*, 3(4):764–777.
- [Olabiyyi et al., 2017] Olabiyyi, O., Martinson, E., Chintalapudi, V., and Guo, R. (2017). Driver action prediction using deep (bidirectional) recurrent neural network. *arXiv preprint arXiv:1706.02257*.

- [Oviatt, 2006] Oviatt, S. (2006). Human-centered design meets cognitive load theory: designing interfaces that help people think. In *Proceedings of the 14th ACM international conference on Multimedia*, pages 871–880.
- [Paddeu et al., 2020] Paddeu, D., Parkhurst, G., and Shergold, I. (2020). Passenger comfort and trust on first-time use of a shared autonomous shuttle vehicle. *Transportation Research Part C: Emerging Technologies*, 115:102604.
- [Parasuraman and Manzey, 2010] Parasuraman, R. and Manzey, D. H. (2010). Complacency and bias in human use of automation: An attentional integration. *Human factors*, 52(3):381–410.
- [Parasuraman and Riley, 1997] Parasuraman, R. and Riley, V. (1997). Humans and automation: Use, misuse, disuse, abuse. *Human factors*, 39(2):230–253.
- [Pearl, 2011] Pearl, J. (2011). Bayesian networks.
- [Peek, 2018] Peek, J. (2018). The drivotrainer was the gran turismo of the 1950s.
- [Perez and Zeadally, 2017] Perez, A. J. and Zeadally, S. (2017). Privacy issues and solutions for consumer wearables. *It Professional*, 20(4):46–56.
- [Phillips et al., 2017] Phillips, D. J., Wheeler, T. A., and Kochenderfer, M. J. (2017). Generalizable intention prediction of human drivers at intersections. In *2017 IEEE intelligent vehicles symposium (IV)*, pages 1665–1670. IEEE.
- [Ping et al., 2018] Ping, P., Sheng, Y., Qin, W., Miyajima, C., and Takeda, K. (2018). Modeling driver risk perception on city roads using deep learning. *IEEE Access*, 6:68850–68866.
- [Piper et al., 2014] Piper, S. K., Krueger, A., Koch, S. P., Mehnert, J., Habermehl, C., Steinbrink, J., Obrig, H., and Schmitz, C. H. (2014). A wearable multi-channel fmirs system for brain imaging in freely moving subjects. *Neuroimage*, 85:64–71.
- [Plavšić et al., 2010] Plavšić, M., Klinker, G., and Bubb, H. (2010). Situation awareness assessment in critical driving situations at intersections by task and human error analysis. *Human Factors and Ergonomics in Manufacturing & Service Industries*, 20(3):177–191.
- [Pollatschek et al., 2002] Pollatschek, M. A., Polus, A., and Livneh, M. (2002). A decision model for gap acceptance and capacity at intersections. *Transportation Research Part B: Methodological*, 36(7):649–663.

- [Radhakrishnan et al., 2020] Radhakrishnan, V., Merat, N., Louw, T., Lenné, M. G., Romano, R., Paschalidis, E., Hajiseyedjavadi, F., Wei, C., and Boer, E. R. (2020). Measuring drivers' physiological response to different vehicle controllers in highly automated driving (had): Opportunities for establishing real-time values of driver discomfort. *Information*, 11(8):390.
- [Ragland et al., 2005] Ragland, D. R., Arroyo, S., Shladover, S. E., Misener, J. A., and Chan, C.-Y. (2005). Gap acceptance for vehicles turning left across on-coming traffic: Implications for.
- [Roßner et al., 2019] Roßner, P., Dittrich, F., Bullinger, A. C., and für Arbeitswissenschaft eV, G. (2019). Diskomfort im hochautomatisierten fahren—eine untersuchung unterschiedlicher fahrstile im fahrsimulator. *Arbeit interdisziplinär analysieren—bewerten—gestalten*, 65.
- [Saffarian et al., 2012] Saffarian, M., De Winter, J. C., and Happee, R. (2012). Automated driving: human-factors issues and design solutions. In *Proceedings of the human factors and ergonomics society annual meeting*, volume 56, pages 2296–2300. Sage Publications Sage CA: Los Angeles, CA.
- [Sagberg et al., 2015] Sagberg, F., Selpi, Bianchi Piccinini, G. F., and Engström, J. (2015). A review of research on driving styles and road safety. *Human factors*, 57(7):1248–1275.
- [Savoy, 2001] Savoy, R. L. (2001). History and future directions of human brain mapping and functional neuroimaging. *Acta psychologica*, 107(1-3):9–42.
- [Schultheis et al., 2007] Schultheis, M. T., Rebimbas, J., Mourant, R., and Millis, S. R. (2007). Examining the usability of a virtual reality driving simulator. *Assistive Technology*, 19(1):1–10.
- [Schütt et al., 2015] Schütt, H., Harmeling, S., Macke, J., and Wichmann, F. (2015). Psignifit 4: Pain-free bayesian inference for psychometric functions. *Journal of vision*, 15(12):474–474.
- [Sensors, 2022] Sensors, A. (2022). BpmsTM body pressure measurement system.
- [Shapley, 1997] Shapley, L. S. (1997). A value for n-person games. *Classics in game theory*, 69.
- [Shimizu et al., 2009] Shimizu, T., Hirose, S., Obara, H., Yanagisawa, K., Tsunashima, H., Marumo, Y., Haji, T., and Taira, M. (2009). Measurement of frontal cortex brain activity attributable to the driving workload and increased attention. *SAE International Journal of Passenger Cars-Mechanical Systems*, 2(1):736–744.

- [Sivak and Schoettle, 2012] Sivak, M. and Schoettle, B. (2012). A note: The changing gender demographics of us drivers. *Traffic injury prevention*, 13(6):575–576.
- [Solhjoo et al., 2019] Solhjoo, S., Haigney, M. C., McBee, E., van Merriënboer, J. J., Schuwirth, L., Artino, A. R., Battista, A., Ratcliffe, T. A., Lee, H. D., and Durning, S. J. (2019). Heart rate and heart rate variability correlate with clinical reasoning performance and self-reported measures of cognitive load. *Scientific reports*, 9(1):1–9.
- [Sowe et al., 2019] Sowe, S. K., Fränzle, M., Osterloh, J.-P., Trende, A., Weber, L., and Lüdtke, A. (2019). Challenges for integrating humans into vehicular cyber-physical systems. In *International Conference on Software Engineering and Formal Methods*, pages 20–26. Springer.
- [Srivastava et al., 2014] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1):1929–1958.
- [Stephenson, 2000] Stephenson, T. A. (2000). An introduction to bayesian network theory and usage. Technical report, Idiap.
- [Štrumbelj and Kononenko, 2014] Štrumbelj, E. and Kononenko, I. (2014). Explaining prediction models and individual predictions with feature contributions. *Knowledge and information systems*, 41(3):647–665.
- [Sun et al., 2020a] Sun, S., Zheng, X., Gong, B., Garcia Paredes, J., and Ordieres-Meré, J. (2020a). Healthy operator 4.0: A human cyber-physical system architecture for smart workplaces. *Sensors*, 20(7):2011.
- [Sun et al., 2020b] Sun, X., Li, J., Tang, P., Zhou, S., Peng, X., Li, H. N., and Wang, Q. (2020b). Exploring personalised autonomous vehicles to influence user trust. *Cognitive Computation*, 12(6):1170–1186.
- [Sztipanovits et al., 2019] Sztipanovits, J., Koutsoukos, X., Karsai, G., Sastry, S., Tomlin, C., Damm, W., Fränzle, M., Rieger, J., Pretschner, A., and Köster, F. (2019). Science of design for societal-scale cyber-physical systems: challenges and opportunities. *Cyber-Physical Systems*, 5(3):145–172.
- [Talebian and Mishra, 2018] Talebian, A. and Mishra, S. (2018). Predicting the adoption of connected autonomous vehicles: A new approach based on the theory of diffusion of innovations. *Transportation Research Part C: Emerging Technologies*, 95:363–380.

- [Taubman-Ben-Ari et al., 2004] Taubman-Ben-Ari, O., Mikulincer, M., and Gillath, O. (2004). The multidimensional driving style inventory—scale construct and validation. *Accident Analysis & Prevention*, 36(3):323–332.
- [Tay, 2007] Tay, Richard und Rifaat, S. M. (2007). Factors contributing to the severity of intersection crashes. *Journal of Advanced Transportation*, 41(3):245–265.
- [Telpaz et al., 2018] Telpaz, A., Baltaxe, M., Hecht, R. M., Cohen-Lazry, G., Degani, A., and Kamhi, G. (2018). An approach for measurement of passenger comfort: real-time classification based on in-cabin and exterior data. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 223–229. IEEE.
- [Thayer and Lane, 2009] Thayer, J. F. and Lane, R. D. (2009). Claude bernard and the heart–brain connection: Further elaboration of a model of neurovisceral integration. *Neuroscience & Biobehavioral Reviews*, 33(2):81–88.
- [Treat et al., 1979] Treat, J. R., Tumbas, N. S., McDonald, S. T., Shinar, D., Hume, R. D., Mayer, R., Stansifer, R., and Castellan, N. J. (1979). Tri-level study of the causes of traffic accidents: final report. executive summary. Technical report, Indiana University, Bloomington, Institute for Research in Public Safety.
- [Trende et al., 2019a] Trende, A., Gräfin, D., and Weber, L. (2019a). Personalized user profiles for autonomous vehicles. In *Proceedings of the 11th International Conference on Automotive User Interfaces and Interactive Vehicular Applications: Adjunct Proceedings*, pages 287–291.
- [Trende et al., 2020] Trende, A., Hartwich, F., Schmidt, C., and Fränzle, M. (2020). Improving the detection of user uncertainty in automated overtaking maneuvers by combining contextual, physiological and individualized user data. In *International Conference on Human-Computer Interaction*, pages 390–397. Springer.
- [Trende et al., 2022] Trende, A., Unni, A., Jablonski, M., Biebl, B., Lüdtke, A., Fränzle, M., and Rieger, J. W. (2022). Driver’s turning intent recognition model based on brain activation and contextual information. *Frontiers in Neuroergonomics*, page 23.
- [Trende et al., 2021] Trende, A., Unni, A., Rieger, J., and Fraenzle, M. (2021). Modelling turning intention in unsignalized intersections with bayesian networks. In *International Conference on Human-Computer Interaction*, pages 289–296. Springer.

- [Trende et al., 2019b] Trende, A., Unni, A., Weber, L., Rieger, J. W., and Luedtke, A. (2019b). An investigation into human-autonomous vs. human-human vehicle interaction in time-critical situations. In *Proceedings of the 12th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, pages 303–304.
- [Unni et al., 2015] Unni, A., Ihme, K., Surm, H., Weber, L., Lüdtkke, A., Nicklas, D., Jipp, M., and Rieger, J. W. (2015). Brain activity measured with fnirs for the prediction of cognitive workload. In *2015 6th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)*, pages 349–354. IEEE.
- [Unni et al., 2022] Unni, A., Trende, A., Pauley, C., Weber, L., Biebl, B., Kacianka, S., Lüdtkke, A., Bengler, K., Pretschner, A., Fränzle, M., et al. (2022). Investigating differences in behavior and brain in human-human and human-autonomous vehicle interactions in time-critical situations. *Frontiers in Neuroergonomics*, 3.
- [van Gent et al., 2018] van Gent, P., Melman, T., Farah, H., Van Nes, N., and van Arem, B. (2018). Multi-level driver workload prediction using machine learning and off-the-shelf sensors. *Transportation research record*, 2672(37):141–152.
- [Vecchiato et al., 2019] Vecchiato, G., Del Vecchio, M., Ascari, L., Antopol'skiy, S., Deon, F., Kubin, L., Ambeck-Madsen, J., Rizzolatti, G., and Avanzini, P. (2019). Electroencephalographic time-frequency patterns of braking and acceleration movement preparation in car driving simulation. *Brain research*, 1716:16–26.
- [Vollrath et al., 2006] Vollrath, M., Briest, S., Schießl, C., Drewes, J., and Becker, U. (2006). Ableitung von anforderungen an fahrerassistenzsysteme aus sicht der verkehrssicherheit.
- [Wyatt et al., 1986] Wyatt, J. S., Delpy, D. T., Cope, M., Wray, S., and Reynolds, E. (1986). Quantification of cerebral oxygenation and haemodynamics in sick newborn infants by near infrared spectrophotometry. *The Lancet*, 328(8515):1063–1066.
- [Wynne et al., 2019] Wynne, R. A., Beanland, V., and Salmon, P. M. (2019). Systematic review of driving simulator validation studies. *Safety science*, 117:138–151.
- [Xu et al., 2014] Xu, Y., Graber, H. L., and Barbour, R. L. (2014). nirslab: a computing environment for fnirs neuroimaging data analysis. In *Biomedical Optics*, pages BM3A–1. Optica Publishing Group.
- [Xu et al., 2022] Xu, Y., Shao, W., Li, J., Yang, K., Wang, W., Huang, H., Lv, C., and Wang, H. (2022). Sind: A drone dataset at signalized intersection in china. In

- 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, pages 2471–2478. IEEE.
- [Yan et al., 2017] Yan, S., Tran, C. C., Wei, Y., and Habiyaremye, J. L. (2017). Driver’s mental workload prediction model based on physiological indices. *International journal of occupational safety and ergonomics*.
- [Yan et al., 2007] Yan, X., Radwan, E., and Guo, D. (2007). Effects of major-road vehicle speed and driver age and gender on left-turn gap acceptance. *Accident Analysis & Prevention*, 39(4):843–852.
- [Yi et al., 2018] Yi, D., Su, J., Liu, C., and Chen, W.-H. (2018). New driver workload prediction using clustering-aided approaches. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 49(1):64–70.
- [Yusof et al., 2016] Yusof, N. M., Karjanto, J., Terken, J., Delbressine, F., Hassan, M. Z., and Rauterberg, M. (2016). The exploration of autonomous vehicle driving styles: preferred longitudinal, lateral, and vertical accelerations. In *Proceedings of the 8th international conference on automotive user interfaces and interactive vehicular applications*, pages 245–252.
- [Zhang et al., 2016] Zhang, G., Yau, K. K., Zhang, X., and Li, Y. (2016). Traffic accidents involving fatigue driving and their extent of casualties. *Accident Analysis & Prevention*, 87:34–42.
- [Zhang et al., 2015] Zhang, H., Chavarriaga, R., Khaliliardali, Z., Gheorghe, L., Iturrate, I., and d R Millán, J. (2015). Eeg-based decoding of error-related brain activity in a real-world driving task. *Journal of neural engineering*, 12(6):066028.
- [Zhang and Fu, 2020] Zhang, H. and Fu, R. (2020). A hybrid approach for turning intention prediction based on time series forecasting and deep learning. *Sensors*, 20(17):4887.
- [Zhang et al., 2020] Zhang, Y., Guo, Z., and Sun, Z. (2020). Driving simulator validity of driving behavior in work zones. *Journal of advanced transportation*, 2020.
- [Zhou et al., 2020] Zhou, F., Alsaïd, A., Blommer, M., Curry, R., Swaminathan, R., Kochhar, D., Talamonti, W., Tijerina, L., and Lei, B. (2020). Driver fatigue transition prediction in highly automated driving using physiological features. *Expert Systems with Applications*, 147:113204.
- [Zhou et al., 2019] Zhou, J., Zhou, Y., Wang, B., and Zang, J. (2019). Human–cyber–physical systems (hcpss) in the context of new-generation intelligent manufacturing. *Engineering*, 5(4):624–636.

-
- [Zhu et al., 2019] Zhu, L., Li, S., Li, Y., Wang, M., Zhang, C., Li, Y., Yao, J., and Ji, H. (2019). Analysis of braking intention based on fnirs in driving simulation experiments. *IET Intelligent Transport Systems*, 13(7):1181–1189.
- [Zohdy et al., 2010] Zohdy, I., Sadek, S., and Rakha, H. A. (2010). Empirical analysis of effects of wait time and rain intensity on driver left-turn gap acceptance behavior. *Transportation research record*, 2173(1):1–10.
- [Zyto, 2022] Zyto (2022). Electrodermal activity monitor.

Abbildungsverzeichnis

1.1	Beispiele für HCPS	4
1.2	Referenzarchitektur für HCPS	5
1.3	Instanziierung HCPS	7
2.1	Beispiele für psychophysiologische Sensorik	24
2.2	Probandin mit fNIRS Kappe	26
2.3	Fahrsimulator der Carl-von-Ossietzky Universität Oldenburg	29
2.4	Beispiel für binäres Klassifikationsmodell	31
2.5	Schematische Darstellung zu Over- und Underfitting	32
2.6	Schematische Darstellung der k-Fold Kreuzvalidierung	33
2.7	Beispiel einer Konfusionsmatrix eines binären Klassifikationsmodells	34
2.8	Beispiel für eine Grenzwertoptimierungskurve	35
2.9	Beispiel für Visualisierung von globalen SHAP Werten	37
2.10	Beispiel Beeswarm Visualisierung einer SHAP Analyse	38
2.11	Bayessches Netz für das Sprinkler Problem	40
2.12	Schematische Abbildung eines KNNs	42
2.13	Schematische Erklärung des Gradientenabstiegsverfahrens	43
3.1	Skizze der durchgeführten Abbiegemanöver	49
3.2	Fahrsimulator mit fNIRS System	51
3.3	Struktur des Bayesschen Netzes	52

3.4	ROC Kurve des Bayesschen Netzes	53
3.5	Beeswarm Abbildung für die SHAP Feature Importance Analyse des Bayesschen Netzes	54
3.6	Absoluten SHAP Werte des Bayesschen Netzes	55
3.7	Schematische Darstellung der fNIRS Datenvorverarbeitung	57
3.8	Boxplot der Accuracys der drei Modelle auf Probandenlevel	58
3.9	Konfusionsmatrizen für alle drei Modelle auf Probandenlevel	59
3.10	ROC Kurven aller drei Modelle auf Probandenlevel	60
3.11	Globale SHAP Werte für das kombinierte Modell	61
3.12	Beeswarm Abbildung der SHAP Werte für das kombinierte Modell	61
3.13	Konfusionsmatrizen für alle drei Modelle auf Gruppenlevel	62
3.14	ROC Kurven aller drei Modelle auf Gruppenlevel	63
3.15	Beeswarm Abbildung der SHAP Werte für das kombinierte Modell und niedrige Kontextwerte	67
4.1	Schematische Abbildung zu mentalem Modell	72
4.2	Schematische Übersicht über die Abbiegesituation im Experiment	75
4.3	Beispiele für HAV und AV in der Simulation	75
4.4	Schematische Darstellung des Bayesschen Netzes zur Klassifikation der Abbiegeentscheidung im hybriden Verkehr.	78
4.5	ROC Kurve für Abbiegeintensionsmodellerkennung im hybriden Verkehr	80
4.6	Lückenakzeptanzwahrscheinlichkeit in Abhängigkeit des Interaktionspartners	84
5.1	Abbildung des Handreglers und einer Überholsituation der Fahrstudie zur Unsicherheitserkennung	92
5.2	Exemplarische Zeitreihen der Feature für Unsicherheitserkennung	94
5.3	ROC und Precision-Recall Analyse der Unsicherheitserkennungsmodelle	96
6.1	Fahrstilparameter Überholmanöver	105
6.2	Simple und komplexes HMI.	106

6.3	DLR dynamischer Fahrsimulator	108
6.4	Beispiele THW Anpassungen	110
6.5	Boxplots angepasste Geschwindigkeiten	114
6.6	Technologieakzeptanz Faktoren	115
7.1	Flowchart adaptive HAV	122

Tabellenverzeichnis

1.1	Übersicht der Arbeit	14
4.1	Prozentualer Anteile an akzeptierten Lücken nach Versuchsbedingung	77
4.2	Ergebnisse des Abbiegemodells im hybriden Verkehrs	80
4.3	Ergebnisse des Fragebogens zu Vertrauen in HAV.	83
5.1	Übersicht der verwendeten Feature für die Unsicherheitserkennung .	95
5.2	Evaluation der Unsicherheitserkennungsmodelle	97
6.1	Fahrstilparameter	109
6.2	MDSI Fahrstilfaktoren	110
6.3	Finale Parameter Konfigurationen	111
6.4	Anzahl der Anpassungen nach Parameter	112
6.5	Angepasste Geschwindigkeiten	113
6.6	Angepasste Geschwindigkeiten	115

Appendix

Fahrstil Fragebogen

Demographische Daten

- Alter
- Geschlecht
- Fahrerfahrung (in Jahren)
- Fahrleistung pro Jahr (in km)
- Fahrsimulatorerfahrung (ja/nein)

Wütendes Fahren

- Ich hupe andere FahrerInnen an.
- Ich hupe um meinen Frust zu zeigen.
- Ich hupe, wenn andere FahrerInnen mich stören.
- Ich beleidige andere FahrerInnen.

Riskantes Fahren

- Ich genieße Nervenkitzel von gefährlichem Fahren.
- Ich gehe Risiken beim Fahren ein.
- Ich genieße das Fahren am Geschwindigkeitslimit.

Ängstliches Fahren

- Ich fühle mich nervös beim Fahren.
- Fahren frustriert mich.
- Ich fühle mich wohl beim Fahren.
- Ich habe die Kontrolle beim Fahren.
- Ich Sorge mich beim Fahren im schlechten Wetter.
- Ich fühle mich angespannt beim Fahren.

Vorsichtiges Fahren

- Ich tendiere dazu vorsichtig zu fahren.
- Ich orientiere mein Verhalten an dem Leitspruch: 'lieber vorsichtig, als bereuen' (eng. 'better safe than sorry').
- Ich fahre am oder unter der Geschwindigkeitsbegrenzung auf der Autobahn.
- Ich halte einen sicheren Abstand zwischen mir und anderen FahrerInnen.
- Ich bin immer bereit auf unerwartete Manöver von anderen FahrerInnen zu reagieren.

Fragen zur präferierten Geschwindigkeit

- Ich fahre schnell.
- Ich fahre über der Geschwindigkeitsbegrenzung auf der Autobahn.
- Ich fahre über der Geschwindigkeitsbegrenzung in der Stadt.

Vertrauen zu autonomen Fahrzeugen (AV)

- Ich habe viel Erfahrung mit AV.
- Ich akzeptiere AV auf der Straße.
- AVs sind sicherer als von Menschen gesteuerte Fahrzeuge.

- Ich vertraue AVs mehr als von Menschen gesteuerten Fahrzeugen.
- Ich verhalte mich bei der Interaktion mit AVs anders als bei der Interaktion mit von Menschen gesteuerten Fahrzeugen.

Technologieakzeptanz Fragebogen

Faktor	Frage	Simple HMI	Komplexes HMI
Performance Expectancy (PE)	This function will be useful while driving	3.77	4.54
	This function will be important aspect in a car	3.92	4.23
	Using this function is convenient to drive	3.85	4.38
Effort Expectancy (EE)	It is difficult to learn how to use this function	1.23 (3.77)	1.85 (3.15)
	It is easy to become skillful about the method of using this function	4.54	4.00
	Using this function is easy and simple to understand	3.38	4.31
Self-Efficacy (SE)	In the case of large amount of time, I will implement this function perfectly	4.38	4.62
	Even though there is no one to let me know how to use it, I will be able to implement this function perfectly	4.38	4.38
	If I have an instruction of using this function, I will be able to implement it perfectly	4.85	4.77
Perceived Safety (PS)	I believe using this function might be dangerous	2.69 (2.31)	2.77 (2.23)
	Using this function does not really bother me to drive	3.62	3.38
	I believe using this function is safe	3.62	3.92

Anxiety (AX)	I am worried about using this function	2.00	1.92
	I believe this function might cause accidents	2.69	2.38
	I am not afraid of using this function	3.62 (1.38)	3.46 (1.54)
Faktor	Frage	Simplex HMI	Komplexes HMI
Trust (T)	I believe this function is verified professionally	4.46	4.62
	I believe this function is reliable	4.54	4.69
	I believe this function will be working in regard to my expectation	3.46	4.15
Affective Satisfaction (AS)	This function makes me satisfied	3.77	4.15
	Overall, this function meets my expectation	4.31	4.15
	I will recommend this function to others	3.31	3.92
Behavior (B)	Henceforth, I am willing to use this function in the future	3.31	4.08
	Henceforth, I am willing to use this function frequently when I will be able to	3.15	4.08
	If it is possible to remain operation continuously, I am willing to use this function consistently	3.38	3.85

