

# FAHRERINTENTIONSERKENNUNG ZUR LICHTBASIERTE K O M M U N I K A T I O N M I T FUSSGÄNGERN

Zur Erlangung des akademischen Grades eines  
DOKTORS DER INGENIEURWISSENSCHAFTEN (Dr.-Ing.)

von der KIT-Fakultät für Elektrotechnik und Informationstechnik des  
Karlsruher Instituts für Technologie (KIT)  
genehmigte

DISSERTATION

von  
Johannes Reschke, M.Sc.

Tag der mündlichen Prüfung: 05. November 2021  
Hauptreferent: Prof. Dr. rer. nat. Cornelius Neumann  
Korreferent: Prof. Dr.-Ing. Eric Sax



No matter where you travel, it's always nice to get home.

**Neil Armstrong, 1969**

---

# ABSTRACT

Im heutigen Straßenverkehr ist neben zahlreichen formellen Regeln stets eine informelle Kommunikation zwischen Verkehrsteilnehmern zu beobachten. Besonders Fußgänger sind auf die Interaktion mit anderen Verkehrsteilnehmern angewiesen und suchen beim Überqueren der Straße Blickkontakt zu Autofahrern. Mit der zunehmenden Automation von Fahrzeugen und dem Einführen automatisierter Systeme wird diese Kommunikation zukünftig entfallen.

Um auch automatisierten Fahrsystemen die Möglichkeit zu geben, mit Fußgängern zu kommunizieren, werden unterschiedliche Konzepte zur Fahrzeug-Fußgänger-Kommunikation evaluiert. Die im Rahmen dieser Arbeit durchgeführte Voruntersuchung mit 35 Teilnehmern und Onlinestudie mit 709 Teilnehmern zeigen, dass Zeichen für eine Fahrzeug-Fußgänger-Kommunikation häufig nicht intuitiv sind und sogar bekannte Symbole nur selten richtig gedeutet werden. In der Voruntersuchung ist lediglich ein Symbol intuitiv verständlich. Dieses Zeichen empfiehlt den Fußgängern anzuhalten und die Straße nicht zu überqueren. In der hier durchgeführten Onlinestudie werden zwei von neun untersuchten Symbolen intuitiv erkannt. Diese visualisieren die Nachricht „Vorfahrt gewähren“, während Zeichen für die Darstellung eines automatisierten Fahrmodus und zur Erkennung eines Fußgängers nur mit vorgegebenen Antworten signifikant verständlich sind. Die Onlinestudie zeigt weiter, dass Farben keine signifikante Unterstützung für die Verständlichkeit von Symbolen darstellen. Die einzige Ausnahme stellt dabei die bereits erlernte Farbe Grün für die Nachricht „Vorfahrt gewähren“ dar. Dies verdeutlicht, dass Zeichen zur Fahrzeug-Fußgänger-Kommunikation nicht intuitiv interpretiert werden können und deren Bedeutungen erst gelernt werden müssen.

Eine Möglichkeit, Zeichen für eine Fahrzeug-Fußgänger-Kommunikation zu erlernen, ist die Symbole bereits im unassistierten Fahrbetrieb anzuzeigen, damit Fußgänger die bestehende informelle Kommunikation mit der neuartigen Fahrzeugkommunikation verbinden können. Hierfür ist vor allem das Erkennen der Fahrerintention an Fußgängerüberwegen notwendig, weshalb

---

---

ein dreistufiger Algorithmus entwickelt wird. Dieser Algorithmus besteht aus einem rekurrenten neuronalen Netzwerk zur Prädiktion von fünf Signalen, einem Random Forest zur Interpretation dieser und einer Plausibilisierung bzw. Entscheidung, ob das Fahrzeug im Prädiktionshorizont von 2 s anhalten wird. Für ein durchschnittliches Fahrverhalten können so Richtig-positiv Raten von 94,0 % und Falsch-positiv Raten von 2,8 % erreicht werden. Mit einer zusätzlichen Personalisierung auf fahrer- bzw. fahrzeugspezifische Merkmale ist eine Prädiktion mit einer Richtig-positiv Rate von 95,6 % und Falsch-positiv Rate von 1,9 % möglich. Das Anpassen des Algorithmus erfolgt dabei mittels Transfer Learning.

Durch Kombination der angepassten Fahrerintentionserkennung und der entwickelten Fahrzeug-Fußgänger-Kommunikation können bereits heutige Fahrzeuge automatisiert mit Fußgängern kommunizieren. Dadurch können diese Symbole für zukünftige Fahrsysteme erlernt und somit die Akzeptanz der automatisierten Fahrzeuge gesteigert werden. Darüber hinaus wird die Kommunikation der Fahrer mit anderen Verkehrsteilnehmern unterstützt.

---

# ERKLÄRUNG

Eidesstattliche Versicherung gemäß § 13 Absatz 2 Ziffer 3 der Promotionsordnung des Karlsruher Instituts für Technologie (KIT) für die KIT-Fakultät für Elektrotechnik und Informationstechnik:

1. Bei der eingereichten Dissertation zu dem Thema „Fahrerintentionserkennung zur lichtbasierten Kommunikation mit Fußgängern“ handelt es sich um meine eigenständig erbrachte Leistung.
2. Ich habe nur die angegebenen Quellen und Hilfsmittel benutzt und mich keiner unzulässigen Hilfe Dritter bedient. Insbesondere habe ich wörtlich oder sinngemäß aus anderen Werken übernommene Inhalte als solche kenntlich gemacht.
3. Die Arbeit oder Teile davon habe ich bislang nicht an einer Hochschule des In- oder Auslands als Bestandteil einer Prüfungs- oder Qualifikationsleistung vorgelegt.
4. Die Richtigkeit der vorstehenden Erklärungen bestätige ich.
5. Die Bedeutung der eidesstattlichen Versicherung und die strafrechtlichen Folgen einer unrichtigen oder unvollständigen eidesstattlichen Versicherung sind mir bekannt.

Ich versichere an Eides statt, dass ich nach bestem Wissen die reine Wahrheit erklärt und nichts verschwiegen habe.

Ingolstadt, den 08. Dezember 2020

.....  
Johannes Reschke



---

# DANKSAGUNG

Diese Arbeit entstand im Rahmen eines Promotionsprojekts in Kooperation zwischen der AUDI AG, Licht und Sicht sowie dem Karlsruher Institut für Technologie, Lichttechnisches Institut.

An erster Stelle möchte ich die Gelegenheit nutzen, mich bei Prof. Dr. rer. nat. Cornelius Neumann für die Übernahme der Betreuung und Erstkorrektur zu bedanken. Vielen Dank für die vielseitig fachliche Unterstützung, für die Hilfe bei der Ausgestaltung des Themas sowie für Deinen Scharfsinn, Deine Erfahrung und Deinen notwendigen Überblick in allen Projektphasen. Vielen Dank besonders dafür, dass Du mir in schwierigen Zeiten Mut zugesprochen hast.

Des Weiteren möchte ich Prof. Dr.-Ing. Eric Sax für die Übernahme des Koreferats und dem damit verbundenen fachlichen Austausch danken. Vielen Dank für Ihren detaillierten und umfangreichen Input sowie Ihr waches Auge bei der Korrektur dieser Arbeit.

Vielen Dank an Dr.-Ing. Wolfgang Huhn und Stephan Berlitz für die Möglichkeit diese Arbeit in der Abteilung Licht und Sicht schreiben zu können, Eure fachliche und persönliche Unterstützung sowie das große Vertrauen, das Ihr in mich setzt.

Mein weiterer Dank gilt allen Kollegen am LTI und in der I/EE-1 für die freundschaftliche Aufnahme in Euer Team sowie die vielen anregenden und oft sehr erheiternden Momente während der Arbeit. Besonders möchte ich hier Dr.-Ing. Melanie Helmer und Philipp Ansorg hervorheben. Vielen Dank für die regelmäßige sowie aufrichtige und herzliche Unterstützung.

Danke auch an alle studentischen Mitarbeiter, die mich während der Promotionszeit begleiteten. Vielen Dank Sebastian Präsl, Rachid Ellouze, Mario Müller, Thomas Höß, Marie-Theres Auburger, Rebeca Marichalar, Benedict Schleyer, Patrick Mathea, Nawel Attia und Leon Mayer für die inhaltliche und sonstige Unterstützung, die mir den Rücken für mein Promotionsprojekt freihielt.

---



---

Vielen Dank an meine Freunde für die außerfachliche Unterstützung und dafür, dass Ihr mich stets daran erinnert, dass es ein Leben außerhalb der Arbeit gibt.

Ein ganz besonderer Dank gilt meiner Familie mit Eltern Monika und Wolfgang, meinem Bruder Michael sowie meiner Freundin Marie-Theres für die vielseitige Unterstützung und den Rückhalt während der Promotionszeit, aber auch während meiner gesamten Ausbildung. Vielen Dank dafür, dass ihr mir die Ausbildung ermöglicht und immer, manchmal mehr als ich selbst, an mich geglaubt habt.

---

# INHALTSVERZEICHNIS

<b>1. Einleitung</b>	<b>1</b>
1.1. Hintergrund und Motivation . . . . .	1
1.2. Aufbau der Arbeit . . . . .	3
<b>2. Grundlagen</b>	<b>5</b>
2.1. Grundlagen der Kommunikation . . . . .	5
2.1.1. Leitlinien für das Symboldesign . . . . .	7
2.1.2. Überblick zur aktuellen Gesetzgebung . . . . .	9
2.2. Grundlagen des automatisierten Fahrens . . . . .	10
2.3. Machine Learning . . . . .	12
2.3.1. Genauigkeitsmaße . . . . .	13
2.3.2. Kreuzvalidierung . . . . .	16
2.4. Feedforward Neural Networks . . . . .	18
2.4.1. Aktivierungsfunktion . . . . .	20
2.4.2. Training neuronaler Netze . . . . .	23
2.4.3. Feature Normalisierung . . . . .	29
2.4.4. Grenzen für Feedforward Netze . . . . .	29
2.5. Recurrent Neural Networks . . . . .	30
2.6. Long Short-Term Memory . . . . .	32
2.6.1. Aufbau einer Long Short-Term Memory Zelle . . . . .	32
2.6.2. Vergleich mit Recurrent Neural Networks . . . . .	34
2.7. Decision Trees . . . . .	35
2.8. Transfer Learning . . . . .	36
<b>3. Stand der Technik</b>	<b>39</b>
3.1. Kommunikation im Straßenverkehr . . . . .	39
3.2. Fahrzeug-Fußgänger-Kommunikation . . . . .	41
3.2.1. Notwendigkeit einer Fahrzeug-Fußgänger-Kommunikation automatisierter Fahrzeuge . . . . .	42
3.2.2. Kommunikationskonzepte automatisierter Fahrzeuge . . . . .	43

---

3.3. Intentionserkennung im Straßenverkehr . . . . .	46
3.4. Absicherung datenbasierter Algorithmen . . . . .	47
3.5. Vergleich von neuronalen Netzen mit konventionellen Algorithmen . . . . .	49
<b>4. Lichtbasierte Fahrzeug-Fußgänger-Kommunikation</b>	<b>51</b>
4.1. Anforderungen an die Kommunikation mit anderen Verkehrsteilnehmern . . . . .	51
4.2. Voruntersuchung zur Intuitivität von Zeichen und Dynamiken	54
4.2.1. Aufbau der Voruntersuchung . . . . .	54
4.2.2. Auswertung und Diskussion der Ergebnisse aus der Voruntersuchung . . . . .	57
4.3. Untersuchung der unterstützenden Wirkung von Farben auf die Verständlichkeit von Symbolen . . . . .	62
4.3.1. Vorbereitung der Onlinestudie . . . . .	63
4.3.2. Aufbau der Onlinestudie . . . . .	69
4.3.3. Auswertung und Diskussion der Onlinestudie . . . . .	73
4.4. Untersuchungskritik . . . . .	84
<b>5. Fahrerintentionserkennung mittels Deep Learning</b>	<b>87</b>
5.1. Anforderungen an eine Fahrerintentionserkennung . . . . .	88
5.1.1. Anwendungsbeispiele für die Fahrerintentionserkennung	88
5.1.2. Anforderungen an das System . . . . .	91
5.1.3. Kritische Bewertung der Anforderungen . . . . .	94
5.2. Datensatz und Labeling der Daten . . . . .	94
5.2.1. Daten für das Vortrainieren . . . . .	94
5.2.2. Verwendete Features . . . . .	98
5.2.3. Durchschnittliche Geschwindigkeitsprofile an Zebrastrifen . . . . .	101
5.2.4. Daten für das Transfer Learning . . . . .	103
5.2.5. Normalisierung der verwendeten Features . . . . .	106
5.3. Aufbau des Algorithmus . . . . .	107
5.3.1. Stufe 1: Prädiktion von Zeitreihen . . . . .	107
5.3.2. Stufe 2: Fahrerintentionserkennung . . . . .	111
5.3.3. Stufe 3: Entscheidung über das Anhalten . . . . .	113

5.4. Training des entwickelten Algorithmus . . . . .	113
5.5. Ergebnisse und Diskussion der Fahrerintentionserkennung . . . . .	117
5.5.1. Vortrainierter Algorithmus . . . . .	117
5.5.2. Nachtrainierter Algorithmus . . . . .	124
5.5.3. Weitere Ergebnisse . . . . .	130
5.6. Untersuchungskritik an der Fahrerintentionserkennung . . . . .	133
<b>6. Zusammenfassung und Ausblick</b>	<b>137</b>
6.1. Zusammenfassung . . . . .	137
6.2. Ausblick . . . . .	143
6.2.1. Zukünftige Forschungsgegenstände . . . . .	144
6.2.2. Anwendung einer Fahrerintentionserkennung zur Fahrzeug-Fußgänger-Kommunikation . . . . .	147
<b>Literaturverzeichnis</b>	<b>151</b>
<b>A. Unterlagen zu den Studien</b>	<b>185</b>
A.1. Voruntersuchung . . . . .	185
A.2. Onlinestudie . . . . .	186
<b>B. Weitere Ergebnisse zur Fahrerintentionserkennung</b>	<b>203</b>
B.1. Regelsatz zur Bestimmung der Fahrerintention . . . . .	203
B.2. Aufgenommene Features . . . . .	206
B.3. Bestimmung der geeigneten Länge einer Referenzstrecke . . . . .	208
B.4. Vergleich verschiedener Netzwerkarchitekturen für das RNN der Fahrerintentionserkennung . . . . .	208
B.5. Bestimmung der Länge für die Eingangssequenzen der Fahrer- intentionserkennung . . . . .	212
<b>C. Veröffentlichungen</b>	<b>213</b>
<b>D. Betreute Arbeiten</b>	<b>215</b>



---

## KAPITEL 1

# EINLEITUNG

Die automobilen Lichttechniken wurden seit ihren Anfängen vor allem durch die Entwicklung sichtverbessernder Systeme geprägt, wobei in den vergangenen Jahren ein Trend hin zur Weiterentwicklung kommunikativer Signalfunktionen erkennbar ist. Bereits die ersten Fahrzeuge waren mit Scheinwerfern zur Sicht bei Nacht ausgestattet, welche im Laufe der Jahre mittels verschiedener Leuchtquellen, wie Halogen- und Gasentladungslampen oder LED- und Laserlichtquellen, verbessert wurden. Im Gegensatz dazu schritt die Entwicklung der Signalfunktionen von Fahrzeugen nach der Einführung der Blink-, Warnblink- oder Bremslichtfunktionen nur langsam voran. Auch außerhalb des Fahrzeugs wurden im Straßenverkehr beispielsweise Ampelanlagen in ihrer Grundfunktion seit Jahrzehnten kaum weiterentwickelt. Mit der Einführung von Pixellichtsystemen, Projektionsscheinwerfern und segmentierten Leuchten am Fahrzeug öffnet sich aktuell eine Tür zur Kommunikation und Interaktion des Fahrzeugs mit dem Fahrer, aber vor allem auch mit anderen Verkehrsteilnehmern.

### 1.1. HINTERGRUND UND MOTIVATION

Schon heute kommunizieren Verkehrsteilnehmer regelmäßig untereinander bzw. zeigen anderen ihre Intention mittels Signaleinrichtungen an. Zu diesen Signaleinrichtungen zählen bspw. Signalhörner, Bremsleuchten und Fahrtrichtungsanzeiger, die bereits seit Mitte des letzten Jahrhunderts für Kraftfahrzeuge gesetzlich verpflichtend sind. Ursprünglich wurden die Zeichen zur Darstellung der Abbiege- oder Anhalteintention mechanisch mittels „Stopplaternen“ und ausklappbaren Richtungsanzeigern umgesetzt [1].

---

Neben formellen, gesetzlich geregelten Signaleinrichtungen des Fahrzeugs haben sich im Laufe der Jahre auch informelle Zeichen zur Kommunikation zwischen Verkehrsteilnehmern etabliert. In über 90 % der Fälle, in denen Fußgänger unter Anwesenheit anderer Verkehrsteilnehmer die Straße überqueren möchten, kommunizieren sie mit diesen [2]. Dafür wird bspw. ein Blickkontakt aufgebaut, die Bewegung von Fahrzeugen und Fußgängern berücksichtigt oder eine Geste eingesetzt [1][3]. Neben Einschränkungen durch Sichtbarkeit der Zeichen, z.B. bei Dunkelheit oder schlechten Sichtverhältnissen [4][5], unterliegen diese Zeichen den persönlichen Normen der Verkehrsteilnehmer [4] und sind daher nicht universell verständlich oder von einheitlicher Bedeutung [3].

Fußgänger sind eine der gefährdetsten Gruppen des Straßenverkehrs, weshalb ihnen u.a. von der National Highway Traffic Safety Administration (NHTSA) empfohlen wird, vor jedem Überqueren der Straße mit anderen Verkehrsteilnehmern zu kommunizieren und Augenkontakt herzustellen [6]. Rund 70-80 % der Verkehrsunfälle geschehen innerorts, wobei seit der Jahrtausendwende die Zahl der verletzten und getöteten Fußgänger sowohl absolut als auch relativ steigt [7][8]. Über 75 % der tödlichen Unfälle mit Fußgängern geschehen nachts bzw. bei Dämmerung [7], was besonders mit schlechten Sichtverhältnissen zusammenhängt.

Für das Vermeiden von Verkehrsunfällen, aber auch um eine erweiterte bzw. komfortablere Mobilität zu ermöglichen, werden aktuell automatisierte Fahrzeuge entwickelt [9]. Eine Kommunikation mit anderen Fahrzeugen, aber vor allem auch mit Fußgängern, wird bei automatisierten Fahrzeugen weiterhin unbedingt notwendig sein, um den Verkehrsfluss sicherzustellen, Vertrauen aufzubauen und Gefahren vorzubeugen [10][11]. Dies gilt insbesondere für Situationen an Fußgängerüberwegen [10]. Darüber hinaus fordert bspw. die Ethik-Kommission des Bundesministeriums für Verkehr und digitale Infrastruktur, dass stets erkennbar sein muss, ob der Fahrer oder das Fahrzeug in Verantwortung der Fahraufgabe steht [9].

Nicht nur automatisierte, sondern auch vom Fahrer gesteuerte Fahrzeuge können die neuartigen Kommunikationsmittel automatisierter Fahrzeuge nutzen, um fahrer- und fahrssystemunabhängig mit Fußgängern zu kommunizieren.

Mit Hilfe der Anzeige einheitlicher Zeichen durch das Fahrzeug ist eine eindeutige Fahrzeug-Fußgänger-Kommunikation, sowohl für automatisierte als auch für unassistierte Fahrzeuge, möglich.

Ziel der Arbeit ist es deshalb, Zeichen für eine möglichst intuitive und verständliche Fahrzeug-Fußgänger-Kommunikation an Fußgängerüberwegen zu finden und ein Kommunikationskonzept für automatisierte und vom Fahrer gesteuerte Fahrzeuge zu erstellen. Dabei sollen neben einfachen Zeichen auch Symbole und Farben zur verständlichen und aussagekräftigen Kommunikation untersucht werden. Außerdem soll eine Fahrerintentionserkennung an Fußgängerüberwegen umgesetzt werden, welche u.a. eine automatische Kommunikation mit Fußgängern ermöglicht und damit sowohl zur Standardisierung als auch zum Erlernen der Zeichen beim unassistierten Fahren beitragen kann. Die Umsetzung der Fahrerintentionserkennung nutzt insbesondere Methoden des maschinellen Lernens und soll durch Interpretation der Verkehrssituation und unterschiedlichster Sensordaten die Intention des Fahrers, an Fußgängerüberwegen anzuhalten, bestimmen.

## **1.2. AUFBAU DER ARBEIT**

Im folgenden Kapitel 2 werden die Grundlagen der Kommunikation, des automatisierten Fahrens und des maschinellen Lernens bzw. tiefen neuronalen Netzen zusammengefasst. Anschließend wird in Kapitel 3 der Stand der Technik zur Kommunikation im Straßenverkehr, der Fahrzeug-Fußgänger-Kommunikation und der (Fahrer-)Intentionserkennung aufgezeigt. In Kapitel 4 wird die Kommunikation mit Fußgängern im Straßenverkehr beschrieben und Anforderungen an die Kommunikation automatisierter Fahrzeuge gestellt. In diesem Kapitel wird nach einer Voruntersuchung zur Intuitivität von Zeichen und Dynamiken eine Onlinestudie zur Evaluation der unterstützten Wirkung von Farben auf die Verständlichkeit von Symbolen vorgestellt. In Kapitel 5 werden anfangs die Anforderungen an die Fahrerintentionserkennung an Fußgängerüberwegen definiert, um anschließend den mehrstufigen Aufbau eines Algorithmus zur Fahrerintentionserkennung an Fußgänger-



überwogen und einen für das maschinelle Lernen benötigten Datensatz zu beschreiben. Im letzten Kapitel 6 werden schließlich die beiden Konzepte der Fahrzeug-Fußgänger-Kommunikation und der Fahrerintentionserkennung zusammengefasst und eine mögliche Implementierung in aktuellen Fahrzeugen vorgeschlagen. Dies stellt einen Ausgangspunkt für zukünftige Untersuchungen dar.

---

## KAPITEL 2

# GRUNDLAGEN


Dieses Kapitel beschreibt die Grundlagen für die Fahrerintentionserkennung zur lichtbasierten Kommunikation mit Fußgängern. Hierfür werden zunächst die Grundlagen der Kommunikation und des automatisierten Fahrens erläutert, um anschließend einen Überblick zum maschinellen Lernen zu geben. Dabei wird insbesondere auf den Aufbau und die Funktionsweise von neuronalen Netzwerken und das Transfer Learning eingegangen.

### 2.1. GRUNDLAGEN DER KOMMUNIKATION

Die Kommunikation zwischen Menschen hat sich über Jahrtausende entwickelt bzw. verfeinert und so ist es nicht verwunderlich, dass sie in allen Teilen des öffentlichen Lebens und insbesondere im Straßenverkehr eine entscheidende Rolle einnimmt [4]. Der Straßenverkehr wird durch formelle Regeln bestimmt, doch ergänzen informelle Regeln und Kommunikation zwischen Verkehrsteilnehmern das offizielle Regelwerk [3]. Obwohl Verkehrsteilnehmer auf frühere Erfahrungen zurückgreifen und auf eine Interaktion mit anderen verzichten, findet bei niedrigen Geschwindigkeiten fast immer eine Kommunikation statt [2][3][12]. Deshalb ist eine Kommunikation vor allem im Stadtgebiet und bei Begegnungen von Fahrzeugen und Fußgängern zu beobachten, z.B. beim Überqueren von Fußgängerüberwegen [12][13]. Verkehrsteilnehmer kommunizieren vor allem, um den Verkehrsfluss aufrechtzuerhalten oder um Gefahren zu vermeiden [3][4]. Hierbei gilt jedoch, dass sie nicht standardisiert handeln und sich die Verhaltensweisen je nach Fahrer, Fußgänger und Situation unterscheiden können [14].

---

Risser [4] beschreibt, dass Kommunikation eine Verständigung zwischen zwei Kommunikationspartnern ist, die entweder bewusst oder im Rahmen eines Automatismus erfolgt. Hierbei möchte ein Partner den anderen anregen, sich auf das eigene Verhalten einzustellen [4]. Eine notwendige Voraussetzung für die erfolgreiche Kommunikation ist, dass beide Kommunikationspartner die gleiche Sprache sprechen und die Nachricht interpretieren können [15]. Diese Kommunikation ist keineswegs statisch, sondern verändert sich fortlaufend über Kommunikationsprozesse [3]. Shannon beschreibt in [16] das sowohl in der Informationstechnik, als auch in der Kommunikation im Straßenverkehr anzuwendende allgemeine Kommunikationsmodell. Demnach tauschen sich eine Informationsquelle bzw. Sender und eine Informationssenke bzw. Empfänger über einen Kanal aus, der durch eine Störquelle beeinflusst wird. Sender und Empfänger kodieren bzw. dekodieren dabei die Nachricht und der Kanal überträgt das Signal (siehe Abbildung 2.1) [16]. Der verwendete Kanal ist in der Kommunikation im Straßenverkehr optischer oder akustischer Natur. Der akustische Kanal findet dabei typischerweise für akute Gefahren oder Warnungen Anwendung, während der optische Kanal universeller bzw. neutraler ist und daher in allen anderen Situationen gewählt wird [4][17].



**Abbildung 2.1.:** Allgemeines Kommunikationsmodell nach Shannon [16]

Diese informelle Kommunikation, welche anders als die formelle Kommunikation nicht durch Regeln beschrieben ist, kann implizit oder explizit erfolgen [18][19]. Die implizite Kommunikation ist im Verhalten eines Verkehrsteilnehmers enthalten, während die explizite Kommunikation ausschließlich für das Senden von Nachrichten durchgeführt wird [19]. Explizite Kommunikation findet nahezu immer über optische Signale statt, da diese hierfür besonders

geeignet sind. Optische Signale sind, anders als akustische Signale, für unbeteiligte Verkehrsteilnehmer kaum wahrnehmbar oder störend und können mittels Blenden und optischen Systemen gerichtet ausgesendet werden [4][20]. Akustische Signale finden daher v.a. für eine Kommunikation in Gefahrensituationen Anwendung, während optische Zeichen universell eingesetzt werden können [20].

Eine erfolgreiche Kommunikation bzw. Deutung der Zeichen setzt voraus, dass diese schnell, eindeutig, für jeden gleichermaßen verständlich und richtig zu erkennen sind [4][21]. Dies trifft v.a. auf Symbole zu, aber auch auf abstrakte Zeichen, welche mit Hilfe einfacher Leuchten oder einzeiliger Leuchtenarrays dargestellt werden können. Mit abstrakten Zeichen wird in diesem Zusammenhang ein einfaches, lichtbasiertes Kommunikationsmittel beschrieben, welches keinen Symbol- oder Textcharakter besitzt. Beispiele hierfür sind Brems-, Blink- oder Warnblinkfunktionen heutiger Fahrzeuge.

Ein Maß dafür, wie verständlich bzw. einfach ein Zeichen zu erkennen ist, ist dessen Intuitivität. Sie gibt an wie intuitiv, also ohne speziellem Vorwissen oder Lernaufwand, ein technisches System benutzt werden kann. Mohs et al. weisen jedoch darauf hin, dass alle Menschen bei der Interaktion und Kommunikation auf Vorwissen zurückgreifen, welches sich sehr früh durch das konzeptuelle Verstehen der physischen Welt ausbildet [22].

### **2.1.1. LEITLINIEN FÜR DAS SYMBOLDESIGN**

Neben einer möglichst intuitiven Gestaltung einfacher Zeichen, wie z.B. kodierter Leuchten (vgl. Kapitel 3.2.2), beschäftigt sich die Literatur vor allem mit dem Design von Symbolen. Um verständliche Symbole zu gestalten muss eine eindeutige Verbindung zwischen dem einzelnen Bild, dem abstrakten Konzept hinter diesem und der darin enthaltenen Kommunikation gezogen werden können [23]. Verständlichkeit und Sinnhaftigkeit sind die beiden wichtigsten Kriterien, die Zeichen in der Kommunikation mit anderen Verkehrsteilnehmern erfüllen sollten [21][23]. Darüber hinaus ist neben einer hohen Erkennungsdistanz entscheidend, dass die Zeichen schnell erkannt

und gedeutet werden können [24]. Diese beiden Kriterien können einander beeinflussen, bspw. wenn die Distanz zu groß ist, um das Symbol schnell zu erkennen. Die Entfernung, bis zu welcher das Signal noch erkannt werden kann, hängt mit der begrenzten Winkelauflösung des menschlichen Auges und technischen Randbedingungen zusammen. Diese sind die Auflösung und der Kontrast des Displays sowie der Abstand einzelner Segmente oder Pixel [25][26]. Um mit bestehenden technischen Gegebenheiten eine möglichst schnelle und sichere Erkennung zu gewährleisten, sollen die zur Kommunikation verwendeten Zeichen bzw. Symbole möglichst schlicht sein. Außerdem sollten sie nach Möglichkeit Objekte aus der physischen Welt stilisiert bzw. vereinfacht darstellen [4][27].

Zeichen mit geringer Intuitivität können ein Zögern der Kommunikationspartner hervorrufen, wodurch in einer zeitkritischen Verkehrssituation das entstandene Risiko größer sein kann als ohne Kommunikation. Deshalb ist es notwendig, dass die Zeichen und Symbole sehr intuitiv oder zumindest nach nur ein paar wenigen Begegnungen erlernbar sind [28]. Budanow et al. zeigen in [29], dass sehr abstrakte Symbole von Probanden nicht intuitiv erkannt, sondern unterschiedlichen Bedeutungen zugeordnet werden. Dennoch ist nach Lagström und Lundgren zu erwarten, dass Symbole genauso erlernt werden können, wie die Zeichen von eindimensionalen Leuchtenarrays [30]. Eine Möglichkeit Zeichen allgemein verständlich einzuführen ist sie zu standardisieren.

Einen Überblick über standardisierte Symbole für Anzeigen, Statusleuchten oder Bedienelementen für Fahrer von Kraftfahrzeugen findet sich in der ISO 2575 [27]. Auch hier werden Objekte aus der physischen Welt stilisiert dargestellt, um bspw. eine Fahrzeugbatterie, Scheinwerfer oder Gefahrenwarnungen anzuzeigen. In Anlehnung an diese ISO Norm werden in der Gesetzgebung für Projektionsscheinwerfer aktuell Symbole zur Kommunikation des Fahrzeugs mit dem jeweiligen Fahrer standardisiert. Das Ziel ist dabei, intuitive Zeichen für eine schnelle und sichere Interaktion zwischen Fahrzeug und Fahrer zu standardisieren.

### 2.1.2. ÜBERBLICK ZUR AKTUELLEN GESETZGEBUNG

Derzeit arbeiten verschiedene Gremien in der Gesetzgebung an der lichttechnischen Umsetzung der Anzeige eines automatisierten Fahrmodus. Dabei hat die Society of Automotive Engineers (SAE) bereits 2019 den Standard SAE J3134 veröffentlicht, in dem auf die Notwendigkeit einer Anzeige des automatisierten Fahrmodus hingewiesen wird und ein Umsetzungsvorschlag präsentiert wird. Dieser Standard sieht eine oder zwei blau-grüne Leuchten in der Fahrzeugfront vor, die je nach Umgebungshelligkeit und Verbau der Leuchten eine Lichtstärke zwischen  $10\text{ cd}$  und  $750\text{ cd}$  im HV-Messpunkt erfüllen müssen. Eine Kommunikation mittels Symbolen wird in dem Standard SAE J3134 ausdrücklich nicht verboten, aber auch nicht näher beschrieben, da sie nicht in die Expertise der Gremienmitglieder fällt. Für zukünftige Standards beschreibt die SAE Norm die Möglichkeit, anzuzeigen, dass ein Fahrzeug Vorfahrt gewährt bzw. bereit ist, lozufahren [31]. Auch die International Organisation for Standardization (ISO) hat mit dem Technical Report ISO 23049 bereits 2018 einen Standard zur Kommunikation automatisierter Fahrzeuge veröffentlicht. Diese Norm behandelt ergonomische Aspekte der Kommunikation und beschreibt bspw., dass die neuartigen Kommunikationsmethoden erlernt werden müssen und daher möglichst gleichartig für alle Fahrzeuge umgesetzt werden sollen. Außerdem weist die Norm darauf hin, dass die Zeichen in allen Verkehrssituationen zuverlässig erkannt werden müssen. Einen detaillierten Vorschlag für die Kommunikation automatisierter Fahrzeuge beschreibt der Technical Report ISO 23049 nicht [32]. Außerdem arbeitet die ISO aktuell an einem noch unveröffentlichten Standard ISO 23735 zur Kommunikation automatisierter Fahrzeuge mit anderen Verkehrsteilnehmern, v.a. Fußgängern. Für den chinesischen Markt wird aktuell ein GB Standard entwickelt, welcher sich neben kleinen Abweichungen größtenteils am SAE J3134 Standard orientiert. Auch die Groupe de Travail Bruxelles 1952 (GTB) arbeitet an einem Vorschlag für die Gesetzgebung, hat aber zum heutigen Zeitpunkt noch keine Ergebnisse veröffentlicht.

Die aktuelle Gesetzgebung ermöglicht keine Umsetzung einer Fahrzeug-Fußgänger-Kommunikation oder Darstellung von Symbolen in bestimmten Situationen. Die UNECE Regulation 48 weist darauf hin, dass sich die pho-

tometrischen Eigenschaften einer Leuchte während des fahrbereit-Zustands nicht ändern dürfen. Diese beinhalten u.a. Lichtstärke bzw. Leuchtdichte, umschriebene und aktive Fläche. Ausnahmen hierfür sind bspw. Reaktionen auf die Änderung der Umgebungshelligkeit, als Reaktion auf das Aktivieren einer anderen Leuchte oder wenn eine Leuchte eine andere Funktion erfüllen soll. Dynamische oder farbige Darstellungen von Signaturen oder Symbolen sind hier ausgeschlossen [33]. Als blinkende Funktionen zulassungsfähig sind v.a. Fahrtrichtungsanzeiger und Warnblinklicht [34] sowie die Funktionsabläufe für das Rear-End Collision Alert Signal (RECAS) und das Emergency Stop Signal (ESS) [33].

In [35] ist ein Alternative für die Darstellung des automatisierten Fahrmodus beschrieben. In diesem Vorschlag werden bestehende Leuchten temporär bzw. lokal moduliert (ca. 0,5 Hz), um damit anzuzeigen, dass sich das Fahrzeug in einem automatisierten Fahrmodus befindet. Diese Idee ist von Darstellungen in Spielen, Filmen und Serien übernommen und deshalb wahrscheinlich bereits in der Bevölkerung bekannt oder schnell zu erlernen. Einzige Abweichung zur aktuellen Fassung der UNECE Regulation 48 ist die Modulation, während die Helligkeits- und Sichtbarkeitsvorgaben stets erfüllt bleiben.

## 2.2. GRUNDLAGEN DES AUTOMATISIERTEN FAHRENS

Aufgrund der aktuellen Aktivitäten in der Gesetzgebung und Standardisierung zur Anzeige eines automatisierten Fahrmodus und einer Fahrzeug-Fußgänger-Kommunikation automatisierter Fahrzeuge (siehe Anhang 2.1.2) erhält dieses Themengebiet große Aufmerksamkeit in der Wissenschaft und Wirtschaft [35]. Vor der Diskussion zur Notwendigkeit einer Fahrzeug-Fußgänger-Kommunikation sollen die in der Ethik-Kommission des Bundesministeriums für Verkehr und digitale Infrastruktur definierten Stufen des automatisierten Fahrens beschrieben werden [9]. Diese sechs Stufen sind den in der SAE J3016 standardisierten Stufen des automatisierten Fahrens sehr ähnlich [36]. In Stufen 0 bis 2 überwiegt der menschliche Anteil an der Fahraufgabe, wobei der Fahrer das System mindestens dauerhaft überwachen muss [9]. Deshalb

werden im Folgenden für diese Stufen die Begriffe „manuelles Fahren“ und „manuelle Fahrzeuge“ eingeführt. In den Stufen 3 bis 5 überwiegt der automatisierte Anteil, d.h. das Fahrzeug übernimmt Längs- und Querführung ohne, dass der Fahrer das System dauerhaft überwachen muss [9]. Deshalb werden diese Stufen automatisierten Fahrzeugen bzw. dem automatisieren Fahren zugeordnet.

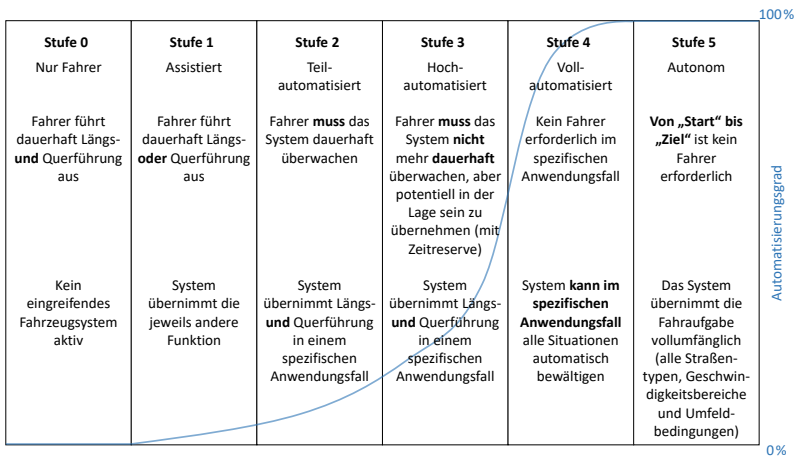


Abbildung 2.2.: Stufen des automatisierten Fahrens, nach [9]

Lichtsignale bzw. Zeichen automatisierter Fahrzeuge können mittels einfacher Leuchten, in kodierter Darstellung oder mit Hilfe von Symbolen dargestellt werden (siehe Kapitel 3.2.2). Unter Zeichen sind allgemein alle Kommunikationsmittel zu verstehen, welche im Prozess einer Kommunikation verwendet werden [3]. Symbole oder Piktogramme werden dagegen in der ISO Norm 2575 als bildlich wahrnehmbare Zeichen definiert, die unabhängig von Sprache eine Information vermitteln. Sie können bspw. reale Gegenstände oder stilisierte Situationen darstellen [27].




## 2.3. MACHINE LEARNING

Ziel des Machine Learnings (maschinellen Lernens) ist es, aus Daten oder Erfahrung zu lernen und Informationen zu gewinnen, um eine bestimmte Aufgabe zu lösen [37]. Nach Mitchell gilt:

A computer program is said to learn from experience  $E$  with respect to some class of tasks  $T$  and performance measure  $P$ , if its performance at tasks in  $T$ , as measured by  $P$ , improves with experience  $E$ . [38]

Hierfür werden Modelle erstellt, welche mehrere Parameter enthalten. Modelle sind entweder prädiktiv, machen also Aussagen über zukünftige Ereignisse, erlangen deskriptiv Wissen aus Daten oder besitzen beide Ausprägungen [37]. Je nach Struktur der Daten spricht man von supervised Learning (überwachtes Lernen) oder unsupervised Learning (unüberwachtes Lernen). Supervised Learning verwendet einen Datensatz bestehend aus Beispielen mit mehreren Features (Merkmalen), wobei jeder Datenvektor  $x$  einem Label  $y$  zugeordnet ist, um daraus ein generalisiertes Modell zu erzeugen. Von unsupervised Learning spricht man, wenn der lernende Algorithmus selbst Strukturen in einem Datensatz finden muss, ohne gelabelte Merkmalsvektoren zu kennen. Neben verschiedenen Mischformen gibt es noch die Möglichkeit des reinforcement Learnings (verstärkendes Lernen), welches sich durch ein Versuch und Irrtum Verfahren auszeichnet [39][40].

Die zentrale Aufgabe im Machine Learning besteht darin, dass ein Algorithmus in einer Trainingsphase lernt, wie er in einer Testphase unbekannte Beispiele von Datenvektoren der Anforderung entsprechend verarbeitet. Dabei müssen die Modelle aus bestehendem Wissen generalisiert werden. Kann der Algorithmus die Struktur des Systems nicht abbilden, so spricht man von Underfitting (Unteranpassung, siehe Abbildung 2.3, a). Overfitting (Überanpassung) liegt vor, wenn das Modell in der Trainingsphase sehr geringe Abweichungen vom Label erzielt, in der Testphase jedoch stark vom Systemcharakter abweicht (siehe Abbildung 2.3, c). Durch Abbilden der Trainingsdaten im Modell des Systems stellt dies eine Art Auswendiglernen dar. In Abbildung 2.3, b ist ein Beispiel für ein gut generalisiertes Modell dargestellt [39].



**Abbildung 2.3.:** Beispiele für Underfitting (a), gute Generalisierung (b) und Overfitting (c) einer quadratischen Funktion, nach [39]

Over- und Underfitting weisen auf das Problem hin, dass, mit endlicher Erfahrung in Form von Daten, kein Modell für alle unbekannt Daten gebildet werden kann. Im Machine Learning werden daher Wahrscheinlichkeiten für Entscheidungen angegeben, welche stets eine bestimmte Unsicherheit aufweisen. Dies wird auch im No Free Lunch Theorem von Wolpert und MacReady deutlich [41]. Demnach gibt es keinen universell besten Algorithmus für jedes beliebige Problem. Der verwendete Datensatz spielt hier eine entscheidende Rolle, wobei es besonders wichtig ist, dass die Trainingsdaten die zu erwartenden Testfälle möglichst gut widerspiegeln [39][41].

### 2.3.1. GENAUGIGKEITSMASSE

Um eine Aussage darüber treffen zu können, wie gut das trainierte Modell die Systemeigenschaften umsetzt, sind unterschiedliche Genauigkeitsmaße erforderlich. Soll bspw. eine Klassifikation bewertet werden, eignen sich u.a. Erkennungsraten oder Richtig-positiv- und Falsch-positiv-Raten. Für Regressionen können keine Trefferraten bestimmt werden, stattdessen sind kontinuierliche Abstandsmaße notwendig.

Ein Beispiel für ein kontinuierliches Abstandsmaß zur Bewertung von Regressionen ist der mittlere quadratische Fehler (Mean Squared Error (MSE)). Dieser berechnet sich nach Kubat [42] als mittlere quadratische Abweichung zwischen dem Label  $y$  und dem prädizierten Wert  $\hat{y}$ :

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \tag{2.1}$$

$m$  gibt dabei die Länge der Vektoren bzw. die Anzahl der Datenpunkte an.

Die Ergebnisse binärer Klassifikatoren lassen sich mit Hilfe einer Wahrheitsmatrix darstellen (vgl. Abbildung 2.4) und die Anzahl der Klassifikationsergebnisse in folgende Kategorien einteilen [43]:

- richtigerweise als positiv klassifiziert (RP)
- fälschlicherweise als positiv klassifiziert (FP)
- richtigerweise als negativ klassifiziert (RN)
- fälschlicherweise als negativ klassifiziert (FN)

Für die Gesamtzahl  $N_{\hat{y}}$  der prädizierten Werte  $\hat{y}$  gilt [42]:

$$N_{\hat{y}} = RP + FP + RN + FN \tag{2.2}$$

		tatsächliche Klasse	
		p	n
ermittelte Klasse	p	Richtig-Positive RP	Falsch-Positive FP
	n	Falsch-Negative FN	Richtig-Negative RN
Summe der Spalten		P	N

**Abbildung 2.4.:** Wahrheitsmatrix, nach [43]

Daraus lässt sich die Treffergenauigkeit bzw. Accuracy bestimmen [43]:

$$accuracy = \frac{RP + RN}{N_{\hat{y}}} \quad (2.3)$$

Dieses Genauigkeitsmaß ist jedoch nur begrenzt zur Bewertung binärer Klassifikatoren geeignet, weil es die Größenverhältnisse der vier Kategorien nicht berücksichtigt. Dies ist in einem kurzen Beispiel erkennbar. Hat eine Klasse 95 Elemente und eine zweite fünf, so berechnet sich die Accuracy bei einer fehlerhaften Zuordnung aller Elemente zur ersten Klasse zu 95 % (nach Gleichung 2.3). Das Ergebnis zeigt jedoch nicht, dass 100 % der Beispiele aus der zweiten Klasse falsch eingeordnet werden [44]. Dieses Problem löst die ROC-Analyse (Receiver Operating Characteristic).

In einer ROC-Analyse lassen sich mit den Größen RP, FP, RN und FN weitere Genauigkeitsmaße für binäre Klassifikatoren berechnen, die eine genaue Aussage über die Klassifikationsgenauigkeit beider Klassen ermöglichen. Die für diese Arbeit relevantesten sind die Richtig-positiv Rate (RPR) und Falsch-positiv Rate (FPR) nach Fawcett [43]:

$$RPR = \frac{RP}{RP + FN} = \frac{RP}{P} \quad (2.4)$$

$$FPR = \frac{FP}{FP + RN} = \frac{FP}{N} \quad (2.5)$$

$P$  ist dabei die Gesamtzahl aller positiven und  $N$  die aller negativen Klassifikationsergebnisse.

Die Summe aus RPR und FPR muss nicht 100 % ergeben, was auch in einem Beispiel für eine ROC-Kurve nach Fawcett deutlich wird (siehe Abbildung 2.5). Die RPRs und FPRs beschreiben alle für den Klassifikator erreichbaren Arbeitspunkte. Für gewöhnlich ist die ROC-Kurve aus diskreten Punkten aufgebaut, doch lassen sich für eine beliebige FPR optimistische, pessimistische oder realistische Schätzungen der RPR in einer ROC-Kurve ablesen (siehe Abbildung 2.5). Für alle Klassifikatoren sind die Werte 0/0 und 1/1 der RPR/FPR in der ROC-Kurve enthalten [43]. Verschiedene Klassifikatoren mit jeweils eigener ROC-Kurve, können für gleiche RPRs unterschiedliche FPRs aufweisen. Demnach können bei konstanter RPR die FPRs einer Schar von Klassifikatoren nicht beliebig klein werden, da diese durch die ROC-Kurven festgelegt sind.

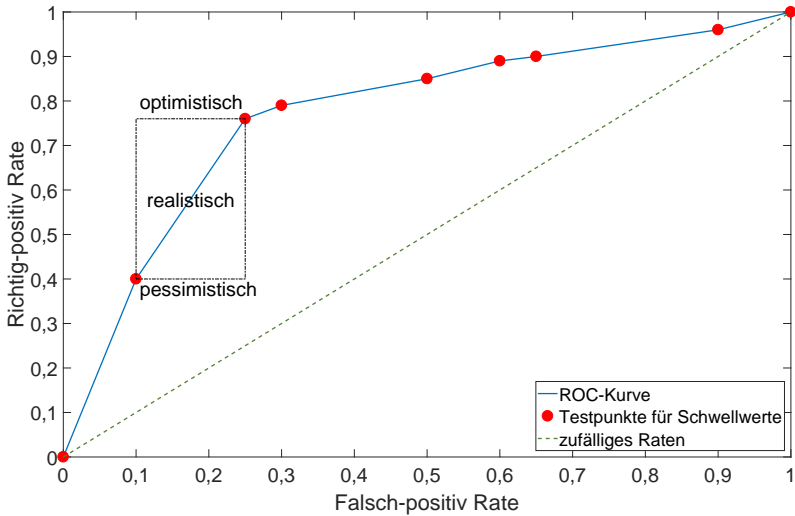


Abbildung 2.5.: Beispielbild für eine ROC-Kurve, nach [43]

### 2.3.2. KREUZVALIDIERUNG

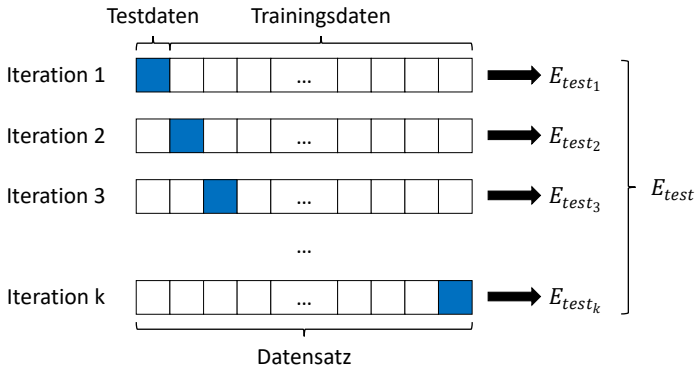
Mittels eines Testdatensatzes kann für jeden Machine Learning Algorithmus ein Testfehler  $E_{test}$  geschätzt werden [45]. Ein fester, kleiner Testdatensatz führt zu einer statistischen Ungenauigkeit bei der Bestimmung des durchschnittlichen Testfehlers, weshalb ein Vergleich zweier Algorithmen nicht zuverlässig getroffen werden kann. Um diesem Problem entgegenzuwirken, kann eine Kreuzvalidierung bzw. Cross-Validation (CV) eingesetzt werden [39].

Bei einer CV wird mit einem Teil des Datensatzes ein Modell trainiert und mit den übrigen Datenpunkten dessen Genauigkeit evaluiert. Dies wird mehrmals wiederholt und die Ergebnisse zusammengefasst [46]. Häufig wird eine  $k$ -fache CV implementiert, welche den Datensatz in  $k$  Teile unterteilt. In jedem  $i$ -ten Durchlauf werden  $k - 1$  Teile für das Trainieren des Modells verwendet,

während der  $i$ -te Anteil zum Testen und zur Bestimmung von  $E_{test_i}$  herangezogen wird (vgl. Abbildung 2.6) [45][46]:

$$E_{test} = \frac{1}{k} \sum_{i=1}^k E_{test_i} \quad (2.6)$$

Nach James et al. [45] steigt mit großen  $k$  ( $k > 10$ ) der Bias der Ergebnisse, wohingegen die Varianz sinkt. Deshalb wird empfohlen Werte von  $k = 5$  oder  $k = 10$  zu verwenden, da diese nach empirischen Versuchen einen Kompromiss für die Schätzung des Testfehlers zwischen Varianz und Bias darstellen [45]. Auch das wiederholte Anwenden einer  $k$ -fachen CV kann zur Verringerung der Varianz bei gleichbleibend geringem Bias führen [46].



**Abbildung 2.6.:**  $k$ -fache Cross-Validation, nach [47]

Zur  $k$ -fachen CV gibt es verschiedene Alternativen in der Aufteilung des Datensatzes in homogene Teile, z.B. die Leave-One-Out Cross-Validation oder die Stratified Cross-Validation nach Kohavi [46]. Die stratifizierte CV unterteilt den Datensatz gleichmäßig, während die Proportionen der Klassen des gesamten Datensatzes in jedem einzelnen Teil wiederzufinden sind [48].

## 2.4. FEEDFORWARD NEURAL NETWORKS

Künstliche neuronale Netze bzw. Artificial Neural Networks (ANNs) sind Machine Learning Modelle, welche nach dem Vorbild des menschlichen Gehirns entworfen wurden [39][49][50] und heute für diverse Anwendungen zum Einsatz kommen. So finden ANNs z.B. in der Bildanalyse, Gesichtserkennung, Spracherkennung und -synthese oder für Kaufentscheidungen an der Börse Anwendung [50]. Besonders wegen ihrer Eigenschaft, nichtlineare Funktionen ohne a priori Wissen schätzen zu können, werden diese Netzwerke auch häufig für Zeitreihenanalysen eingesetzt [51]. Alle ANNs akquirieren und speichern die aus Daten gewonnenen Informationen in künstlichen Neuronen [50]. Eine der einfachsten Architekturen und Sonderform der ANNs sind Feedforward Neural Networks (FNNs), welche Informationen in Form von Eingangsvektoren geradlinig durch verschiedene Schichten weitergeben [39]. Weil keine Rückkopplung der Ergebnisse zum Eingang erfolgt, werden diese auch azyklische Netzwerke genannt [52].

Die Geschichte der ANNs reicht bis in die 1940er Jahre zurück, als erste Netzwerke und deren Potential, aus Daten zu lernen, vorgestellt wurden. Die zum Lernen der richtigen Gewichte notwendige Backpropagation konnte erst in den 1970er Jahren durch neue Algorithmen effizient umgesetzt werden. Damit, sowie durch die steigende Leistungsfähigkeit der Recheneinheiten, erleben ANNs seit den 1990er Jahren einen immensen Aufschwung und beherrschen seit einigen Jahren alle Machine Learning Wettbewerbe unterschiedlichster Disziplinen [52].

Wie beschrieben sind v.a. für die Modellierung tiefer neuronaler Netze zeitintensive Berechnungen notwendig, wobei sich Trainings- und Klassifikationszeit um mehrere Größenordnungen voneinander unterscheiden können. Das Training ist um eine Vielzahl rechenintensiver als das einmalige Verarbeiten eines Eingangsdatenvektors, weshalb u.a. Krizhevsky et al. für das Training von ANNs den Einsatz von parallel arbeitenden Grafikkarten empfehlen [53].

Jedes neuronale Netzwerk besteht aus einer Vielzahl künstlicher Neuronen (siehe Abbildung 2.7), welche mittels eines Eingangsvektors  $x$ , eines Gewichts-

vektors  $\mathbf{W}$ , eines Bias  $\theta$  und einer Aktivierungsfunktion  $g(\cdot)$  (siehe Kapitel 2.4.1) den Ausgabewert  $\hat{y}$  bestimmen [39], wobei

$$\mathbf{W} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} \quad (2.7)$$

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (2.8)$$

gilt. Die Aktivierung  $z$  wird über die Summe der mit  $\mathbf{W}$  gewichteten Eingänge und dem Bias  $\theta$  berechnet [39].

$$z = \mathbf{W}^T \mathbf{x} + \theta \quad (2.9)$$


Damit ergibt sich der Ausgangswert  $\hat{y}$  zu [39][50]

$$\hat{y} = \hat{f}(\mathbf{x}) = g(z) \quad (2.10)$$

Das künstliche Neuron speichert die aus den Daten gewonnen Informationen im Gewichtsvektor  $\mathbf{W}$  und dem Bias  $\theta$ , wobei durch Kombination mehrerer Neuronen komplexere Informationen verarbeitet bzw. vernetztere Modelle gebildet werden können [50].

Die Kombination der künstlichen Neuronen erfolgt in Schichten, welche ebenfalls durch Gewichte  $\mathbf{W}$  miteinander verbunden sind (einfache Pfeile in Abbildung 2.8). Wird jedes künstliche Neuron einer Schicht mit allen Neuronen oder Eingängen der vorherigen Schicht durch ein Gewicht verknüpft, so spricht man von einem fully connected (FC) Layer [40]. Bei FNNs sind diese Schichten ohne Rückkopplung aufgebaut. Jedes ANN besitzt eine Eingangsschicht (Input Layer) und eine Ausgangsschicht (Output Layer). Zwischen diesen sind typischerweise eine oder mehrere verdeckte Schichten (Hidden Layer) implementiert. Besitzt ein ANN mehrere verdeckte Schichten, so wird dieses als tief bezeichnet und demnach Deep Neural Network (DNN) genannt [39].





**Abbildung 2.7.:** Künstliches Neuron, nach [39][50]

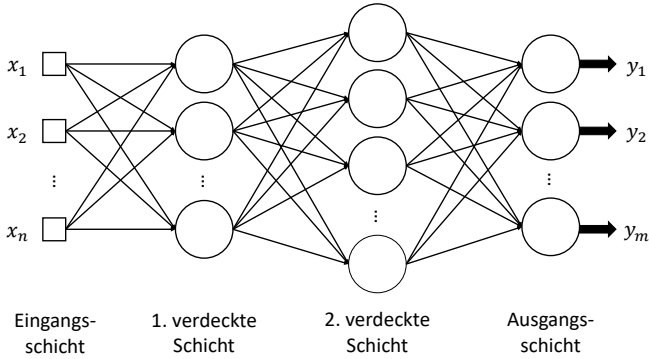
DNNs übertreffen konventionelle Algorithmen in unterschiedlichen Anwendungsfeldern, wie etwa Übersetzung, Spracherkennung oder Bilderkennung, bei weitem [49] und können durch Verkettung der Funktionen jeder Schicht (siehe Gleichung 2.11) gegenüber flachen Netzen Neuronen sparen [54]. Die Tiefe des in Abbildung 2.8 dargestellten Netzwerks beträgt drei, weshalb gilt [39]:

$$\hat{f}(x) = \hat{f}^{(3)}(\hat{f}^{(2)}(\hat{f}^{(1)}(x))) \quad (2.11)$$

### 2.4.1. AKTIVIERUNGSFUNKTION

Aktivierungsfunktionen  $g(\cdot)$  sind beliebige Funktionen künstlicher Neuronen, wobei insbesondere nichtlineare Funktionen eingesetzt werden, um Nichtlinearitäten in ANNs abbilden zu können. Häufig verwendete Aktivierungsfunktionen, sogenannte Hidden Units, sind die binäre Treppenfunktion, logistische Sigmoidfunktion, Tangens hyperbolicus (tanh) und Rectified Linear Unit (ReLU) (siehe Abbildung 2.9) [39][50]. Darüber hinaus besteht auch die Möglichkeit, keine Aktivierungsfunktion einzusetzen [39].

Beschränkte Aktivierungsfunktionen wie die binäre Treppenfunktion, logistische Sigmoidfunktion oder tanh führen bei Recurrent Neural Networks



**Abbildung 2.8.:** Beispiel für ein kleines neuronales Netzwerk mit drei fully connected Layern und  $m$  Ausgängen, nach [50]

(RNNs) zu verschwindenden Gradienten, wohingegen unbeschränkte Funktionen, wie z.B. die Rectified Linear Unit, zu explodierenden Gradienten führen können (siehe Kapitel 2.5) [55].

### Binäre Treppenfunktion

Die binäre Treppenfunktion ist eine der einfachsten Aktivierungsfunktionen und gibt für positive Eingänge einen Wert von 1 zurück, für negative 0. Die Treppenfunktion wird deshalb auch als Schwellwertfunktion bezeichnet und kann folgendermaßen beschrieben werden [50]:

$$g(z) = \begin{cases} 0 & \text{wenn } z < 0 \\ 1 & \text{wenn } z \geq 0 \end{cases} \quad (2.12)$$

Weil die Ableitung dieser Aktivierungsfunktion im Punkt  $z = 0$  wegen der Unstetigkeit nicht existiert und die Treppenfunktion nur zwei Werte annehmen kann, werden v.a. für tiefe Netze und stetige Neuronen andere Aktivierungsfunktionen eingesetzt [50][57].

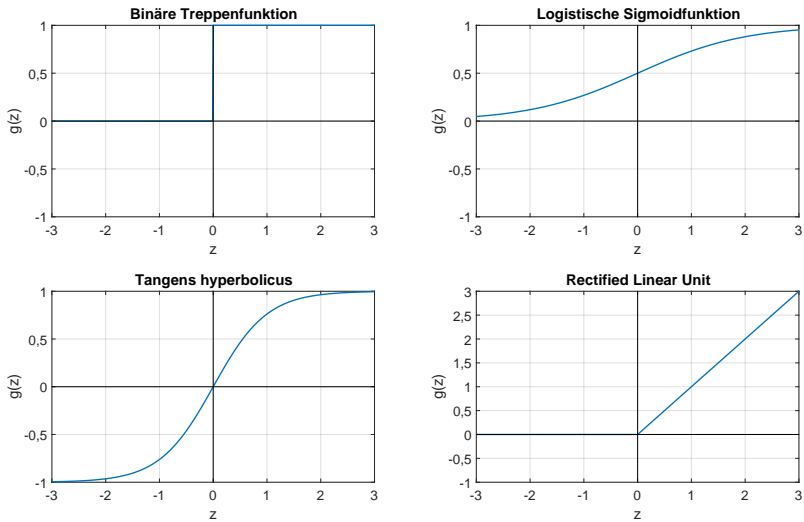


Abbildung 2.9.: Beispiele für Aktivierungsfunktionen  $g(z)$ , nach [50][56]

### Logistische Sigmoidfunktion

Zu den stetig differenzierbaren Aktivierungsfunktionen zählt die logistische Sigmoidfunktion, welche eine geglättete Treppenfunktion ist [57]. Die logistische Sigmoid Aktivierungsfunktion kann folgendermaßen beschrieben werden [39][50]:

$$g(z) = \sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.13)$$

Wie in Abbildung 2.9 dargestellt ist, zeigt die logistische Sigmoidfunktion um  $z = 0$  ihre größte Empfindlichkeit und nähert sich für  $z > 3$  und  $z < -3$  den Grenzwerten 1 und 0 an, was v.a. bei FNNs das Lernen erschwert. Für RNNs, probabilistische Modelle oder Autoencoder werden trotzdem logistische Sigmoidfunktionen eingesetzt, da sie hierfür zusätzliche Anforderungen erfüllen, z.B. eine bijektive Abbildung von  $z$  auf  $g(z)$  [39].

### Tangens hyperbolicus

Soll bei FNNs trotz der oben genannten Einschränkung eine sigmoidförmige Funktion eingesetzt werden, wird von Goodfellow et al. besonders ein Tangens hyperbolicus als Aktivierungsfunktion empfohlen [39]:

$$g(z) = \tanh(z) = 2\sigma(2z) - 1 \quad (2.14)$$

Die Form des Tangens hyperbolicus ähnelt für betragsmäßig kleine Aktivierungen  $z$  der identischen Abbildung, was das Training von ANNs vereinfacht [39].

### Rectified Linear Unit

Die ReLU ist der Aktivierungsfunktion des biologischen Neurons sehr ähnlich und durch ihre Übereinstimmung mit der identischen Abbildung für  $z \geq 0$  sehr effizient beim Trainieren von ANNs [56]:

$$g(z) = \max(0, z) = \begin{cases} 0 & \text{wenn } z < 0 \\ z & \text{wenn } z \geq 0 \end{cases} \quad (2.15)$$

Durch die linearen Funktionsteile (außer bei  $z = 0$ ) und dem großen Anteil von 0-Werten (für  $z < 0$ ) sind die Berechnungen tiefer Netzwerke bei zufälliger Initialisierung besonders effizient. Bei positiven Aktivierungen  $z$  kann die unbeschränkte, identische Abbildung zu ungewollt großen Ergebnissen führen und damit den Trainings- und Klassifikationsvorgang negativ beeinflussen. Dies kann nach Glorot et al. durch eine Regularisierung verhindert werden [56].

## 2.4.2. TRAINING NEURONALER NETZE

Beim Training neuronaler Netze steht die Optimierung einer Kostenfunktion  $E(\theta, W)$  für ein bestehendes Problem im Mittelpunkt [40][58]. Die zentrale

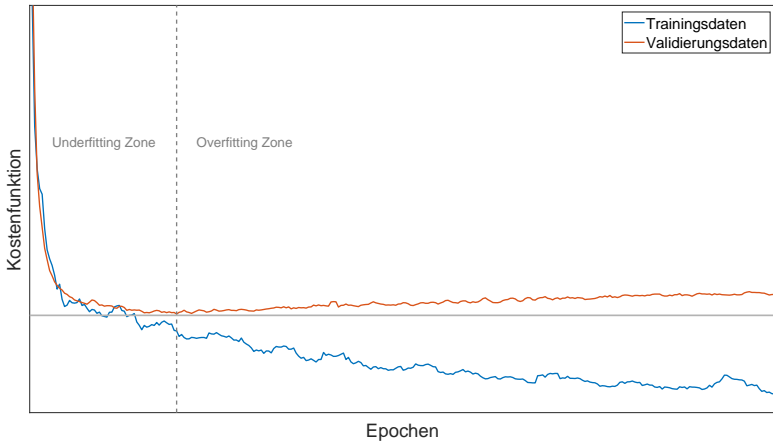
Aufgabe beim Trainieren des Netzwerks ist es, die Parameter  $\theta$  und  $W$  so anzupassen, sodass die Kostenfunktion  $E(\theta, W)$  für einen bestehenden Datensatz minimal wird [59]. Dies geschieht durch mehrmaliges Anwenden eines Optimizers auf die zur Verfügung stehenden Daten. Eine Trainingsiteration über den gesamten Datensatz wird dabei Epoche genannt [39].

Die Bias  $\theta$  und Gewichte  $W$ , mit  $\omega = (W; \theta^T)$  [58], werden in heutigen DNNs vor allem mit gradientenbasierten Optimizern trainiert [39]. Ein weit verbreiteter Optimizer ist der Gradient Descent Algorithmus, welcher über eine berechnete Schätzung des Gradienten und eine Lernrate  $\varepsilon$  die Gewichte eines ANN trainieren kann. Fortgeschrittenere Algorithmen wie der Adam Optimizer verwenden zusätzlich adaptiv geschätzte Momente niedriger Ordnung [60]. Die Lernrate  $\varepsilon$  ist im einfachsten Fall eine kleine, konstante Zahl, kann jedoch auch über verschiedene Methoden über die Anzahl der Epochen angepasst werden (z.B. bei RMSProp oder dem Adam Optimizer) [39][59]. Wird die Lernrate zu groß gewählt, kann der Algorithmus das lokale Minimum nicht erreichen bzw. überspringt beim weiteren Optimieren dieses wieder. Zu kleine Schrittweiten der Lernrate führen zu sehr langen Trainingszeiten [59].

Die Initialisierung der Parameter  $\omega$  wird in modernen Algorithmen nach wie vor sehr einfach umgesetzt. Es ist entscheidend, dass die Parameter mit unterschiedlichen Werten initialisiert werden, damit die einzelnen Neuronen nicht im gleichen Umfang angepasst bzw. trainiert werden. Dies kann beispielsweise über zufällige Initialisierung geschehen, wobei die Zufallsverteilung nahezu keinen Einfluss hat. Nach Goodfellow et al. fehlen jedoch genaue Erkenntnisse, wie sich die Initialisierung auf das Training des ANNs auswirkt [39].

Beim Training eines neuronalen Netzes sinkt die Kostenfunktion für die Trainingsdaten typischerweise über alle Epochen, was zu einem Overfitting führen kann. Um diesem Problem entgegenzuwirken, kann ein Validierungsdatensatz verwendet werden, für welchen zyklisch die Kostenfunktion berechnet wird. Der Validierungsdatensatz wird nicht für das Training selbst verwendet, sondern lediglich um den Trainingsfortschritt zu überprüfen. Wie in Abbildung 2.10 zu sehen ist, steigt dessen Kostenfunktion nach einigen Epochen typischerweise wieder an, was auf ein Overfitting hindeutet. Weil im Bereich vor diesem Wendepunkt ein zu wenig angepasstes Modell vorliegt

(Underfitting) ist es erstrebenswert, die Parameter aus dem Wendepunkt zu speichern. Dieses Speichern des Modells im Wendepunkt der Lernkurve und der Abbruch des Trainings wird Early Stopping (frühes Anhalten) genannt. Die Verwendung eines Validierungsdatensatzes für das Early Stopping entspricht der Wirkungsweise einer  $L^2$ -Regularisierung [39]. Der Hauptnutzen der Regularisierung ist das Vermeiden des Overfittings, wofür auch andere Regularisierungsmethoden eingesetzt werden können [59].



**Abbildung 2.10.:** Lernkurven für Trainings- und Validierungsdaten, nach [39]

Die genaue Bestimmung der Gradienten über alle Daten ist sehr rechenintensiv, weshalb eine effizientere Berechnungen der Gradienten die Trainingsdauer stark verkürzen kann. Dafür werden die Daten in zufällig ausgewählte Teilmengen, sogenannte Minibatches, unterteilt und mit diesen über mehrere Iterationen der Gradient geschätzt [39][59]. Ist die Batch-Size, also wie viele Datenpunkte gleichzeitig betrachtet werden, zu gering oder sogar 1, so wird die verwendete Hardware nicht effizient genutzt und es kann zu einer Überanpassung an einzelne Datenpunkte kommen [59]. Deshalb wird die Batch-Size für ANNs zwischen 1 und der Größe des Datensatzes gewählt [39], wobei nach Radiuk größere Batch-Sizes zu höheren Prädiktionsgenauigkeiten führen [61]. Hier muss ein Kompromiss zwischen Berechnungseffizienz bzw.

Hardwareauslastung und Prädiktionsgenauigkeit gefunden werden. Unbedingt notwendig ist, dass die Minibatches zufällig ausgewählt werden [39], wodurch die verwendete Kostenfunktion jedoch zur stochastischen Funktion werden könnte [60].

## Kostenfunktionen

Eine Kostenfunktion  $E(\omega)$  (error function, cost function) ist ein Maß für die Abweichung zwischen den vom ANN prädizierten Ausgangswerten  $\hat{y}$  und den eigentlichen Labelwerten  $y$ . Diese kann auf unterschiedliche Arten bestimmt werden, wobei quadratische Kostenfunktionen (quadratic loss)

$$E(\omega) = (y - \hat{y})^2 \quad (2.16)$$

oder absolute Kostenfunktionen (absolute loss)

$$E(\omega) = |y - \hat{y}| \quad (2.17)$$

wegen ihrer Einfachheit und Effektivität eingesetzt werden [58]. Des Weiteren wird die Kostenfunktion LogLoss insbesondere für Klassifikationsprobleme verwendet und ist durch folgende Gleichung beschrieben [62][63]:

$$E(\omega) = -y \cdot \log(\hat{y} + eps) - (1 - y) \cdot \log(1 - \hat{y} + eps) \quad (2.18)$$

Hier gibt  $eps$  die jeweilige Maschinengenauigkeit an.

## Optimizer

Gradientenbasierte Optimizer werden in verschiedenen Machine Learning Anwendungen eingesetzt, um eine Kostenfunktion  $E(\omega)$  unter Berücksichtigung der Parameter  $\omega$  zu minimieren. Mit Hilfe gradientenbasierter Optimizer werden die Gradienten der Kostenfunktion  $\nabla E(\omega)$  auf Basis weniger Datenpunkte des Datensatzes geschätzt, z.B. bei Verwendung von Minibatches [39][60].

Einer der am einfachsten nachzuvollziehenden Optimizer ist der Gradient Descent Algorithmus, bei dem der Gradient

$$\nabla E(\boldsymbol{\omega}) = \begin{bmatrix} \frac{\delta E(\boldsymbol{\omega})}{\delta \omega_1} \\ \frac{\delta E(\boldsymbol{\omega})}{\delta \omega_2} \\ \vdots \\ \frac{\delta E(\boldsymbol{\omega})}{\delta \omega_n} \end{bmatrix} \quad (2.19)$$

und die Lernrate  $\varepsilon$  zur Aktualisierung der neuen Gewichte und Bias  $\boldsymbol{\omega}'$  verwendet werden. Hierbei gilt [39][40]:

$$\boldsymbol{\omega}' = \boldsymbol{\omega} - \varepsilon \nabla E(\boldsymbol{\omega}) \quad (2.20)$$

Der Gradient Descent Algorithmus ist vor allem für differenzierbare Kostenfunktionen ein effizienter Optimizer, weil die Berechnung der partiellen ersten Ableitungen genauso rechenaufwändig ist, wie die Evaluierung der Funktion selbst. Für stochastische Kostenfunktionen, z.B. durch Unterteilen des Datensatzes in Minibatches, ist dieser Algorithmus jedoch nur eingeschränkt zu verwenden [60].

Für die Anwendung bei stochastischen Kostenfunktionen gibt es eine Reihe von Optimizern, z.B. stochastische Gradient Descent, AdaGrad oder RMS-Prop, wobei sich vor allem der Adam Optimizer durchgesetzt hat [39][60]. Der Name Adam leitet sich von adaptive moment estimation (adaptive Moment-schätzung) ab. Diese Methode berechnet neben der ersten partiellen Ableitung  $\nabla E(\boldsymbol{\omega})$  auch das erste und zweite Moment des Gradienten  $\mathbf{m}_1$  und  $\mathbf{m}_2$ , um eine adaptive Lernrate zu bestimmen und damit die Gewichte und Bias  $\boldsymbol{\omega}$  zu trainieren [60]:

$$\boldsymbol{\omega}' = \boldsymbol{\omega} - \alpha \frac{\widehat{\mathbf{m}}_1'}{\sqrt{\widehat{\mathbf{m}}_2'} + \varepsilon} \quad (2.21)$$

Dabei stellt  $\alpha$  die Schrittweite dar und mit  $\widehat{\mathbf{m}}_1'$  bzw.  $\widehat{\mathbf{m}}_2'$  werden die um den Bias korrigierten ersten und zweiten Momente angegeben:

$$\widehat{\mathbf{m}}_1' = \frac{\mathbf{m}_1'}{1 - \beta_1^t} \quad (2.22)$$



$$\widehat{m}_2' = \frac{m_2'}{1 - \beta_2^t} \quad (2.23)$$

Hierbei sind  $\beta_1$  und  $\beta_2$  die exponentiellen Abklingraten des ersten und zweiten Moments. Die Zeitschritte  $t$  werden bei jeder Iteration inkrementiert. Die aktualisierten ersten und zweiten Momentschätzungen  $m_1'$  und  $m_2'$  werden aus den Vorgängerschätzung  $m_1$  und  $m_2$  berechnet [60]:

$$m_1' = \beta_1 \cdot m_1 + (1 - \beta_1) \nabla E(\omega) \quad (2.24)$$

$$m_2' = \beta_2 \cdot m_2 + (1 - \beta_2) (\nabla E(\omega) \odot \nabla E(\omega)) \quad (2.25)$$

Dabei beschreibt  $\nabla E(\omega) \odot \nabla E(\omega)$  das elementweise Produkt aus  $\nabla E(\omega)$  [60]. Obwohl der Adam Optimizer sehr robust gegenüber der Initialisierung der verwendeten Parameter ist und nur in manchen Fällen eine Anpassung der Lernrate erforderlich ist [39], empfehlen Kingma und Ba die Initialisierung von  $\alpha = 0,001$ ,  $\beta_1 = 0,9$ ,  $\beta_2 = 0,999$  und  $\varepsilon = 10^{-8}$  [60].

## Backpropagation

Im Algorithmus zur Backpropagation wird die Kettenregel der Differentialrechnung in einer speziellen Reihenfolge angewendet, damit die Berechnung möglichst effizient durchgeführt werden kann [39]:

$$\frac{dz}{dx} = \frac{dz}{dy} \frac{dy}{dx} \quad (2.26)$$

In diesem Beispiel sind  $f$  und  $g$  skalare Funktionen für die  $y = g(x)$  und  $z = f(g(x)) = f(y)$  gilt.

Der Backpropagation Algorithmus kann den Gradienten einer Kostenfunktion mit Hilfe rückwärts durch das Netzwerk fließender Informationen berechnen. Dieser wird wiederum für gradientenbasierte Optimizer zum Training von ANNs eingesetzt [39]. Die Backpropagation führte durch effizientes Berechnen der Gradienten ab 1981 zu erheblichen Fortschritten in der Entwicklung von neuronalen Netzen [52]. Eine numerische Berechnung des Gradienten ist im Gegensatz zur analytischen Berechnung sehr rechenintensiv, weshalb der Backpropagation Algorithmus in nahezu allen modernen ANNs eingesetzt wird [39].

### 2.4.3. FEATURE NORMALISIERUNG

Für die Berechnung neuronaler Netze unter der Anwendung einer Kostenfunktion ist es notwendig, die verwendeten Daten zu normalisieren. Die Kostenfunktion bezieht nach ihrer Definition die absoluten Abweichungen aller Prädiktionen vom Label ein, wodurch manche Merkmale einen größeren Einfluss auf das Fehlermaß haben als andere. Die Feature Normalisierung hilft dabei, dass sich alle Daten in der gleichen Größenordnung befinden und damit nur relative Änderungen der Features betrachtet werden [64][65]. Die Normalisierung beschränkt die Datenpunkte der Merkmalsvektoren auf einen definierten Bereich, z.B.  $[0; 1]$  oder  $[-1; 1]$ . Dadurch wird ein effizienteres Berechnen und damit ein schnelleres Training der ANNs möglich [50][65].

Eine simple Methode zur Feature Normalisierung ist die Min-Max Normalisierung, bei der jeder  $i$ -te Datenpunkt  $x_{ij}$  eines Features  $j$  mit Hilfe des jeweiligen Minimums  $min_j$  und Maximums  $max_j$  auf einen Bereich  $[0; 1]$  beschränkt wird [64]:

$$x'_{ij} = \frac{x_{ij} - min_j}{max_j - min_j} \quad (2.27)$$

Eine weitere Möglichkeit der Feature Normalisierung ist die Anwendung einer tanh Funktion für das Beschränken der Daten auf den Bereich  $[-1; 1]$ , wobei auch Abwandlungen von dieser verwendet werden können. Eine dieser ist die modifizierte Tanh Normalisierung nach Thangasamy und Latha [66]:

$$x'_{ij} = 0,5 \left( \tanh \left( \frac{0,01(x_{ij} - \mu_j)}{\sigma_j} \right) + 1 \right) \quad (2.28)$$

Der Mittelwert  $\mu_j$  und die Standardabweichung  $\sigma_j$  werden dabei direkt aus den zugrundeliegenden Daten berechnet. Die Daten werden wie bei der Min-Max Normalisierung auf einen Bereich von  $[0; 1]$  beschränkt [66].


### 2.4.4. GRENZEN FÜR FEEDFORWARD NETZE

ANNs haben sich für verschiedenste Anwendungen bewährt und sind ein wichtiges Hilfsmittel, um komplexe Zusammenhänge zu modellieren [39][52].

Jedoch verarbeiten die oben beschriebenen Feedforward Netze jeweils nur einen Inputvektor  $x$ , also einen Zeitschritt, ohne vorhergehende Ergebnisse miteinzubeziehen [39]. Zwar lassen sich zeitliche Zusammenhänge beschreiben [39][67], doch können Modelle für Sequenzen variabler Länge kaum gebildet werden. Tritt eine bestimmte Information an unterschiedlichen Positionen der Sequenz auf, so muss das Netzwerk für alle möglichen Konfigurationen trainiert werden [39].

## 2.5. RECCURENT NEURAL NETWORKS

Recurrent Neural Networks sind ANNs mit zyklischen Netzwerktypologien, womit sie Informationen aus sequentiellen Zusammenhängen herausfiltern und speichern können [52][68]. Wie in Abbildung 2.11 dargestellt, wird hierfür die Ausgabe bestimmter Neuronen als Eingang für diese und andere Neuronen zurückgeführt [50]. Durch die Rückführung und der damit verbundenen Fähigkeit sequentielle Daten zu verarbeiten, übertreffen RNNs hierbei klassische FNNs, wie z.B. bei der Analyse von Zeitreihen, bei der Prozesssteuerung oder bei der Systemidentifikation und -optimierung [50][68].



**Abbildung 2.11.:** Hidden State eines Recurrent Neural Networks in kompakter und zeitlich entfalteter Darstellung, nach [39]

Mit Hilfe der rekurrenten Vernetzung der Neuronen können RNNs Parameter über mehrere Zeitschritte hinweg teilen, wodurch sehr tiefe Modelle entstehen. Damit lassen sich im Gegensatz zu FNNs lange Sequenzen von Eingangsvariablen verarbeiten. Das Teilen der Parameter ist entscheidend,

wenn Informationen an verschiedenen Positionen der Sequenz auftreten können. FNNs müssen in diesem Fall für jede Position der Information neue Features erlernen [39]. Obwohl RNNs in der Praxis häufig mit Minibatches trainiert werden [39], können sie theoretisch Sequenzen variabler Größe analysieren [39][68].

Zum Training eines RNNs wird ein Hidden State (versteckter Zustand)  $\mathbf{h}^{(t)}$  als eine Art Zusammenfassung der bis  $t$  vergangenen Zeitschritte berechnet. Der Hidden State ist generell verlustbehaftet, da er eine Eingangssequenz beliebiger Länge  $(\mathbf{x}^{(t)}, \mathbf{x}^{(t-1)}, \mathbf{x}^{(t-2)}, \dots, \mathbf{x}^{(2)}, \mathbf{x}^{(1)})$  auf einen Vektor  $\mathbf{h}^{(t)}$  fester Länge abbildet. Während des Trainingsprozesses werden bestimmte Eingangsgrößen stärker berücksichtigt als andere [39]:

$$\mathbf{h}^{(t)} = f(\mathbf{h}^{(t-1)}, \mathbf{x}^{(t)}, \boldsymbol{\omega}) \quad (2.29)$$

Das Training von RNNs wird nach zeitlichem Entfalten des Modells wie bei FNNs durchgeführt, wofür mit Hilfe eines Backpropagation Algorithmus Gradienten berechnet werden (vgl. Kapitel 2.4). Durch die zeitliche Entfaltung des Graphen wird dies als Backpropagation through time (Backpropagation über die Zeit) bezeichnet. Die Gradienten werden anschließend, wie auch für FNNs, in gradientenbasierten Optimizern eingesetzt, womit wiederum das Netzwerk trainiert werden kann. Durch das serielle Verketteten von RNNs oder dem Abzweigen von rekurrenten Pfaden werden tiefe RNNs aufgebaut [39].

ANNs mit beschränkten Aktivierungsfunktionen, insbesondere aber auch RNNs leiden unter dem Problem der vanishing oder exploding gradients, also verschwindenden oder explodierenden Gradienten [55]. Die Ursache für die vanishing und exploding gradients liegt dabei in der Aktualisierung der Gewichte im Optimizer bzw. in der Berechnung der Gewichte selbst. Diese gehen entweder zu gering (bei verschwindenden Gradienten) oder zu stark (bei explodierenden Gradienten) in den Gradienten der Fehlerfunktion ein [69]. Dies erschwert einerseits das Optimieren der RNNs erheblich [55] und führt andererseits dazu, dass sie kaum Langzeitabhängigkeiten abbilden können, sondern lediglich für kurzzeitige Zusammenhänge geeignet sind [68]. Bei sehr tiefen FNNs und auch bei RNNs gehen die Gradienten einer beliebigen Schicht durch Anwendung der Kettenregel als Produkt in die Berechnung

der Gradienten darüberliegender Schichten bzw. vorausgehender Zeitschritte ein. Dadurch können die Gradienten verschwinden bzw. explodieren, vor allem unter Einsatz konstanter Gewichte, wie sie bei RNNs durch die zeitliche Entfaltung anzutreffen sind [64].


Vanishing gradients sind für RNNs nur sehr schwer zu vermeiden und treten wesentlich häufiger als exploding gradients auf [39][69]. Eine Möglichkeit vanishing gradients zu vermeiden ist das Initialisieren der Gewichte mit kleinen Werten um 0, wobei sich dadurch sehr lange Trainingsdauern einstellen [69]. Alternativ werden in aktuellen Anwendungen deshalb gated bzw. verschlossene RNNs eingesetzt [39].

## 2.6. LONG SHORT-TERM MEMORY

Long Short-Term Memory (LSTM) Zellen (langes Kurzzeitgedächtnis) sind gated RNNs, die mit Hilfe eines direkten Pfads durch das Netzwerk robust gegen verschwindende und explodierende Gradienten sind und damit zeitliche Zusammenhänge modellieren können [39][70]. Die Kombination aus dem direkten Pfad und den verwendeten Gates lies die LSTM zu einer der erfolgreichsten rekurrenten Netzwerkarchitektur für sequentielle Zusammenhänge werden [39][55]. Hochreiter und Schmidhuber [71] entwickelten den ursprünglichen Aufbau einer LSTM Zelle, welcher seitdem mehrfach ergänzt oder abgewandelt wurde [39][72].

### 2.6.1. AUFBAU EINER LONG SHORT-TERM MEMORY ZELLE

Jede LSTM Zelle besteht neben einem internen Zustand (internal State) oder Zellenzustand (Cell State) [39], welcher den verdeckten Zustand einer RNN Zelle ersetzt, aus drei Gates (siehe Abbildung 2.12) [70][71]. Der interne Zustand  $s_i^{(t)}$  der Zelle  $i$  ist die wichtigste Komponente einer LSTM Zelle, da er einen direkten Pfad für die Backpropagation darstellt und die relevanten Informationen einer Sequenz beinhaltet [39].



**Abbildung 2.12.:** Aufbau einer Long Short-Term Memory Zelle, nach [39][73]

Das Forget Gate (Vergessenstor)  $f_i^{(t)}$  bestimmt mit Hilfe einer Sigmoidfunktion welche Informationen aus dem Zellenzustand vergessen oder beibehalten werden sollen [70][71]. Das Forget Gate wird folgendermaßen berechnet [39]:

$$f_i^{(t)} = \sigma\left(\theta_i^f + \sum_j \mathbf{u}_{i,j}^f \mathbf{x}_j^{(t)} + \sum_j \mathbf{w}_{i,j}^f \mathbf{y}_j^{(t-1)}\right) \quad (2.30)$$

Dabei sind  $\mathbf{u}_i^f$  bzw.  $\mathbf{w}_i^f$  und  $\theta_i^f$  jeweils die Gewichte und Bias des Forget Gates,  $\mathbf{x}_j^{(t)}$  der Eingangsdatenvektor für den Zeitpunkt  $t$  und  $\mathbf{y}_j^{(t-1)}$  der Output Vektor für den vorhergehenden Zeitpunkt  $t - 1$ .

Das Input Gate (Eingangstor)  $g_i^{(t)}$  bestimmt welche Informationen aus dem aktuellen Eingangsdatenvektor  $\mathbf{x}_j^{(t)}$  und Output Vektor  $\mathbf{y}_j^{(t-1)}$  in den internen Zustand fließen sollen [39]:

$$g_i^{(t)} = \sigma\left(\theta_i^g + \sum_j \mathbf{u}_{i,j}^g \mathbf{x}_j^{(t)} + \sum_j \mathbf{w}_{i,j}^g \mathbf{y}_j^{(t-1)}\right) \quad (2.31)$$

Mit dem aktuellen Eingang

$$\tilde{s}_i^{(t)} = \sigma\left(\theta_i^s + \sum_j \mathbf{U}_{i,j}^s \mathbf{x}_j^{(t)} + \sum_j \mathbf{W}_{i,j}^s \mathbf{y}_j^{(t-1)}\right) \quad (2.32)$$

wird der Zellenzustand wie folgt berechnet [39]:

$$\mathbf{s}_i^{(t)} = \mathbf{f}_i^{(t)} \mathbf{s}_i^{(t-1)} + \mathbf{g}_i^{(t)} \tilde{s}_i^{(t)} \quad (2.33)$$

Mit Hilfe des Output Gates (Ausgangstor)  $\mathbf{q}_i^{(t)}$  wird im LSTM eingestellt, wie viele Informationen aus dem internen Zustand an den Ausgang  $\mathbf{y}_i^{(t)}$  weitergegeben werden [39]:

$$\mathbf{q}_i^{(t)} = \sigma\left(\theta_i^q + \sum_j \mathbf{U}_{i,j}^q \mathbf{x}_j^{(t)} + \sum_j \mathbf{W}_{i,j}^q \mathbf{y}_j^{(t-1)}\right) \quad (2.34)$$

$$\mathbf{y}_i^{(t)} = \tanh(\mathbf{s}_i^{(t)} \mathbf{q}_i^{(t)}) \quad (2.35)$$

## 2.6.2. VERGLEICH MIT RECURRENT NEURAL NETWORKS

Im Gegensatz zu RNNs sind LSTMs kaum von verschwindenden oder explodierenden Gradienten betroffen und können deshalb besonders lange Sequenzen zuverlässig verarbeiten [70]. Außerdem können sie dadurch schneller sequentielle Zusammenhänge erlernen [39][71], weshalb sie in den meisten Anwendungen RNNs vorgezogen werden. Vor allem durch den direkten Pfad des Zellenzustandes können die LSTMs sehr lange Zeitreihen verarbeiten und Informationen zuverlässig speichern. Hochreiter und Schmidhuber beschreiben das erfolgreiche Analysieren von Sequenzen bis zu einer Länge von 1000 Schritten. Im Vergleich mit einer einfachen rekurrenten Zelle besitzt eine LSTM Zelle zusätzliche Gates, wodurch viermal so viele Parameter pro Epoche berechnet und aktualisiert werden müssen [71].

## 2.7. DECISION TREES

Decision Trees (Entscheidungsbäume) sind, im Gegensatz zu RNNs, klassische Algorithmen des maschinellen Lernens und werden vor allem wegen ihres einfachen Aufbaus eingesetzt. Sie bestehen aus einer Vielzahl von in Schichten angeordneter Entscheidungen oder Bedingungen und sind weit verbreitete Algorithmen für Klassifikationsaufgaben, also Entscheidungen mit diskreten Ausgangswerten. Der zugrundeliegende Algorithmus sucht zu jedem Verzweigungspunkt nach einem Schwellwert, welcher die Datenvektoren mit den hinterlegten Labels möglichst eindeutig in zwei Gruppen aufteilt. Werden beim Training des Decision Trees zu viele Verzweigungen zum Baum hinzugefügt ist ein Overfitting zu erwarten, bei sehr wenigen kann es zu einem Underfitting kommen [38][74].

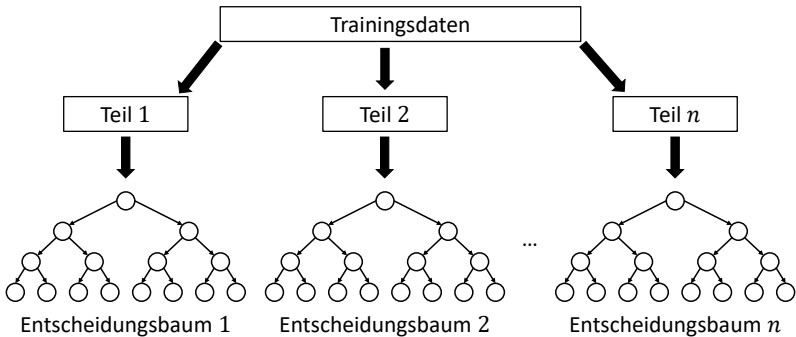


Abbildung 2.13.: Aufbau von Random Forests, nach [75]

Random Forests (Zufallswälder) bestehen aus  $n$  Entscheidungsbäumen und können sowohl für Klassifikations-, als auch für Regressionsaufgaben eingesetzt werden. Bei der Regression gibt es, anders als bei der Klassifikation, keine diskreten Ergebnisse, sondern kontinuierliche Wertebereiche. Im Training der Random Forests wird ein zugrundeliegender Datensatz auf  $n$ , zufällig ausgewählte Datensätze aufgeteilt. Jede dieser Teilmengen wird wie oben beschrieben für die Erstellung eines Decision Trees verwendet. Zur Klassifikation wird ein Datenvektor durch alle Entscheidungsbäume bewertet. Anschließend

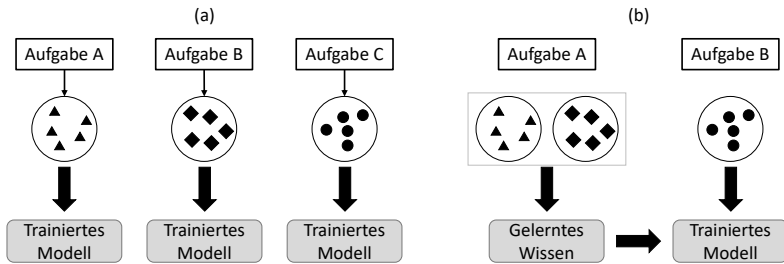


wird aus allen Ergebnissen, z.B. mittels Mehrheitsprinzip oder Vergleich mit einem Schwellwert, eine Entscheidung gebildet. Für eine Regression können bspw. alle Ausgänge der einzelnen Decision Trees gemittelt werden [38][76].

## 2.8. TRANSFER LEARNING

Transfer Learning ist die Fähigkeit eines Systems gelerntes Wissen aus einer oder mehreren Aufgaben bzw. Bereichen  $A$  in eine andere, neue Aufgabe bzw. Bereich  $B$  zu übertragen [77]. Hierfür kann beispielsweise ein ANN mit Trainingsdaten aus  $A$  vortrainiert werden, um anschließend mit einer kleineren Anzahl von Daten aus  $B$  nachtrainiert zu werden (vgl. Abbildung 2.14) [39][77]. Dadurch kann das ANN schneller und mit weniger Daten als in einer klassischen Herangehensweise trainiert werden, bei der das Netzwerk mit zufällig initialisierten Neuronen trainiert wird. Außerdem können mit diesem Ansatz genauere Prädiktionen erreicht werden [78]. Neben ANNs können klassische Machine Learning Algorithmen, wie z.B. Decision Trees oder Random Forests, mittels Transfer Learning an eine spezielle Aufgabe angepasst werden [79]. Auch Menschen machen sich das Übertragen von Wissen aus einem oder mehreren Bereichen in einen neuen Bereich zu Nutze, um schneller lernen zu können [77][78]. Gleiches ist im Machine Learning möglich und kann für Klassifikations-, Regressions- und Clusteringaufgaben eingesetzt werden [77].

Das Transfer Learning zum Übertragen von Wissen in ein neues Modell kann auf verschiedene Arten durchgeführt werden. Eine Möglichkeit besteht darin, alle Parameter des Modells mittels Fine Tuning (Feinabpassung) an die neue Aufgabe anzupassen. Dies geschieht indem die Parameter des ANNs durch Trainieren mit dem initialen Datenset der Aufgabe  $A$  trainiert bzw. initialisiert und durch Training mit einer kleinen Lernrate an die Aufgabe  $B$  angepasst werden [80][81]. Durch das vollständige Nachtrainieren aller Parameter erlaubt diese Variante im Vergleich zu den nachfolgend beschriebenen ein nur sehr langsames Training [81]. Ist der Datensatz der Aufgabe  $B$  klein und die



**Abbildung 2.14.:** Funktionsprinzip von klassischen ANNs (a) und Transfer Learning (b), nach [77]

Anzahl der Parameter groß, kann es durch das Fine Tuning des ANN zu Overfitting kommen [80].

Eine weitere Alternative für das Transfer Learning neuronaler Netze ist das Hinzufügen einer oder mehrerer Schichten vor dem Output Layer. Hier wird das ursprüngliche Netzwerk mit den Daten aus *A* vortrainiert, neue Schichten hinzugefügt und schließlich werden diese mit dem Datensatz *B* an eine spezielle Aufgabe angepasst bzw. trainiert. Durch erneutes Training einer oder weniger Schichten, fällt die Trainingszeit für das Transfer Learning kürzer aus, als für das Fine Tuning, während v.a. für kleine Datensätze *B* gute Ergebnisse erzielt werden können. Enthalten die hinzugefügten Schichten jedoch sehr viele Parameter und ist der Datensatz *B* klein, können diese Schichten nicht ausreichend trainiert werden [81].

Eine letzte Methode des Transfer Learnings ist das Anpassen bzw. Nachtrainieren einzelner Schichten, wobei die Parameter aller anderen Schichten den Wert der vortrainierten Aufgabe *A* beibehalten. Das Nachtrainieren der ersten Schichten des ANNs ist v.a. für Anwendungen sinnvoll, bei denen *A* und *B* gleiche Ausgabewerte aber unterschiedliche Eingangsdaten aufweisen (z.B. Spracherkennung) [39][81]. Im Gegensatz dazu sollten für ähnliche Eingangsdaten und unterschiedliche Ausgänge vor allem die letzten Schichten nachtrainiert werden [39].

Transfer Learning findet heute in verschiedenen Bereichen Anwendung, v.a. dann, wenn für ein bestimmtes Problem nur sehr wenige Trainingsdaten

zur Verfügungen stehen [39]. Dies betrifft insbesondere medizinische Anwendungen, wie z.B. die medizinische Bildverarbeitung bei der Erkennung von Speiseröhrenkrebs [82] oder dem Klassifizieren von Melanomen [83][84]. Weitere Anwendungsbereiche sind die Analyse von Webdaten, z.B. sozialer Medien [49], oder die Analyse von Zeitreihen [85]. Domeyer et al. zeigen in ihrer Studie, dass sich auch das Fahrverhalten von Fahrern an Zebrastreifen messbar unterscheidet und deshalb fahrerspezifische Unterschiede betrachtet werden sollten [86]. Weil die generelle Aufgabe das Fahrverhalten zu erkennen gleich bleibt, bietet sich ein Transfer Learning mit einem allgemein trainierten Algorithmus an.

---

## KAPITEL 3

# STAND DER TECHNIK

Dieses Kapitel zeigt den Stand der Technik für die Kommunikation und (Fahrer-) Intentionserkennung im Straßenverkehr auf. Dafür wird zunächst die Kommunikation von Verkehrsteilnehmern analysiert und daraus die Notwendigkeit der Fahrzeug-Fußgänger-Kommunikation automatisierter Fahrzeuge abgeleitet. Anschließend werden bereits bekannte Konzepte einer Intentionserkennung im Straßenverkehr und die Absicherung datenbasierter Algorithmen betrachtet. Zuletzt wird ein Vergleich von neuronalen Netzen und konventionellen Algorithmen vorgenommen.

### 3.1. KOMMUNIKATION IM STRASSENVERKEHR

Im heutigen Straßenverkehr ist eine Kommunikation zwischen Verkehrsteilnehmern omnipräsent. Das Ziel jeder Kommunikation zwischen Verkehrsteilnehmern ist nach Merten das Vermeiden bzw. das Minimieren von Gefahren [3], wobei v.a. Fußgänger, und diese insbesondere bei Nacht, gefährdet sind [7][13][87]. Des Weiteren findet eine Kommunikation zwischen Verkehrsteilnehmern auch statt, um den Verkehrsfluss sicherzustellen oder fehlende Regelungen und Störungen zu kompensieren [3][88]. Prinzipiell ist der Straßenverkehr durch Regeln geordnet, doch können damit einige Situationen nicht eindeutig festgelegt werden [88]. Solche Situationen können durch eine Kommunikation bzw. Interaktion gelöst werden [89]. Zusätzlich findet eine Kommunikation beispielsweise zur Warnung, Danksagung oder Entschuldigung Anwendung [3][4], wobei sie vor allem für Fußgänger an Fußgängerüberwegen entscheidend ist [10]. So empfiehlt bspw. die NHTSA und

---

das US-Verkehrsministerium allen Fußgängern, den geltenden Regeln nur eingeschränkt zu vertrauen und unbedingt Augenkontakt mit Fahrern sich annähernder Fahrzeuge herzustellen [6]. Folglich nutzen Fußgänger die Kommunikation an Fußgängerüberwegen um sich abzusichern, von Fahrern gesehen worden zu sein und Vorfahrt gewährt zu bekommen [19], v.a. wenn keine Verkehrsschilder oder -ampeln die Situation eindeutig regeln [2]. Zusätzlich wird die Kommunikation von vielen Fußgängern eingesetzt, um die Aufmerksamkeit anderer Verkehrsteilnehmer zu erhöhen [18]. Bei fehlender Kommunikation verlieren Fußgänger das Vertrauen in andere Verkehrsteilnehmer und fühlen sich unsicher [90][91].

Aus diesen Gründen kommunizieren nach Rasouli et al. über 90 % der Fußgänger bevor sie die Straße überqueren auf unterschiedlichste Arten, mindestens durch einen kurzen Blick auf das sich annähernde Fahrzeug [2]. Neben der Schematismenbildung, z.B. aufgrund von Fahrzeugtyp oder Fahrweise [4][88], und implizierter Kommunikation, z.B. durch Bewegung, Körperhaltung oder Distanzverhalten [3][17], ist im Straßenverkehr vor allem eine explizite Kommunikation anzutreffen. Für eine explizite Kommunikation setzen Verkehrsteilnehmer v.a. Gestik und Mimik, z.B. Kopfnicken oder Handzeichen [3], und Mitteilungen über technische Einrichtungen des Fahrzeugs ein, z.B. (Licht-) Hupe oder Fahrtrichtungsanzeiger [4]. Darüber hinaus spielt der Blickkontakt zwischen zwei Verkehrsteilnehmern, z.B. Fahrer und Fußgänger, bei der expliziten Kommunikation eine entscheidende Rolle. Dieser Blickkontakt ist im engeren Sinn kein Zeichen einer Kommunikation, sondern ein Mittel, diese zu starten [3][10]. Trotzdem wird der Blickkontakt häufig als eine der wichtigsten Arten der Kommunikation beschrieben und findet in fast jeder Interaktion Anwendung [2][12][92][93]. Es scheint, als sei ein Blickkontakt weniger eindeutig oder verlässlich als vorgeschriebene Zeichen, wie z.B. eine Lichthupe, doch ist dies nicht der Fall [4]. Informelle Zeichen spielen im heutigen Straßenverkehr eine bedeutende Rolle, auch wenn sie je nach Situation oder Verkehrsteilnehmer in Verwendung, Ausprägung und Bedeutung variieren können [4][88].

Bei der Kommunikation im heutigen Straßenverkehr ergeben sich einige Schwierigkeiten, welche v.a. auf die Verständlichkeit der Signale bzw. der zugrundeliegenden Nachricht zurückzuführen sind. Eine mögliche Ursache

für eine gescheiterte Kommunikation ist, dass das Signal, wegen zu geringer Aufmerksamkeit oder zu großer Störung des Kanals, nicht als solches wahrgenommen wird [3]. Obwohl der Blickkontakt zu mindestens 90 % beim Überqueren einer Straße eingesetzt wird (siehe oben), ist gerade dieser von dem Problem betroffen, nicht als Signal wahrgenommen zu werden. Er ist nur auf eine sehr kurze Distanz zuverlässig erkennbar [94] und kann z.B. durch das Spiegeln der Scheiben beeinträchtigt werden [95]. Auch Dunkelheit und schlechte Sichtverhältnisse erschweren die Kommunikation zwischen Verkehrsteilnehmern [4][5]. Eine weitere Schwierigkeit für die Kommunikation ist die richtige Wahrnehmung auf der Bedeutungsebene bzw. das Dekodieren des Signals in eine sinnvolle Nachricht [3]. Die meisten der heute verwendeten Signale sind mehrdeutig und können teilweise nicht oder sogar konträr gedeutet werden [4][88]. Dies ist vor allem durch die begrenzten Möglichkeiten einer Kommunikation im Straßenverkehr bedingt [30]. Eine falsch interpretierte Nachricht, v.a. bei konträrer Deutung, kann erhebliche Risiken hervorrufen [28]. In diesem Zusammenhang ist als weitere Einschränkung der Kommunikation im Straßenverkehr zu nennen, dass es keinen standardisierten Verkehrsteilnehmer gibt [14]. So sind v.a. international und kulturell ausgeprägte Unterschiede im Kommunikationsverhalten zu beobachten [17][88]. Zuletzt sind im Straßenverkehr häufig Situationen anzutreffen, in denen möglichst schnell mit unterschiedlichen Verkehrsteilnehmern kommuniziert werden muss, weshalb sich die Kommunikation auf eine möglichst kurze Dauer beschränkt [3]. Aus diesem Grund findet teilweise keine Kommunikation statt, wobei dies auch durch die Anonymität im Verkehrsraum und der vermittelten Sicherheit des eigenen Fahrzeugs als eine Art Schutzschild begünstigt wird [3][4].

### **3.2. FAHRZEUG-FUSSGÄNGER-KOMMUNIKATION**

Eine Fahrzeug-Fußgänger-Kommunikation ermöglicht einerseits Signale zwischen Fahrer und Fußgänger sowohl einheitlich als auch eindeutig erkennbar

auszutauschen und andererseits, dass automatisierte Fahrzeuge mit anderen Verkehrsteilnehmern interagieren.

### **3.2.1. NOTWENDIGKEIT EINER FAHRZEUG-FUSSGÄNGER-KOMMUNIKATION AUTOMATISierter FAHRZEUGE**

Im heutigen Straßenverkehr sind die zur Kommunikation verwendeten Zeichen nicht immer eindeutig oder sichtbar. Jedoch können mit Hilfe einer Kommunikation durch das Fahrzeug die informellen Zeichen des Fahrers ergänzt werden, um die gewünschte Nachricht eindeutig und zuverlässig übermitteln zu können. Darüber hinaus besteht vor allem bei automatisierten Fahrzeugen ein hoher Bedarf zur Kommunikation mit anderen Verkehrsteilnehmern, um insbesondere das Sicherheitsempfinden von Fußgängern zu steigern.

Assistierte und automatisierte Fahrzeuge werden laufend weiterentwickelt und sind immer häufiger anzutreffen [9][96]. Mittlerweile gibt es zahlreiche Teststrecken in Europa, USA und Asien und auch automatisierte Serienfahrzeuge stehen vor einer zeitnahen Markteinführung [96][97]. Diese werden unter Hochdruck entwickelt, da der Einsatz automatisierter Fahrzeuge vor allem zu einer deutlich höheren Straßenverkehrssicherheit führt [9]. Außerdem kann durch vollautomatisierte Fahrzeuge die Mobilität für bestimmte Personengruppen, z.B. Alte, Kinder oder Gehbehinderte, erhöht werden [30][91].

Den Vorteilen automatisierter Fahrzeuge kann entgegengesetzt werden, dass kein Fahrer für die Kommunikation mit anderen Verkehrsteilnehmern im Fahrzeug zur Verfügung steht bzw. dieser als Passagier nicht aufmerksam am Verkehr teilnimmt [86]. Aus diesem Grund ist die in Kapitel 3.1 beschriebene Kommunikation zwischen Verkehrsteilnehmern, v.a. zwischen Fahrer und Fußgänger, nicht mehr vorhanden. Damit werden auch die Gründe für die Kommunikation im heutigen Straßenverkehr, wie Sicherstellen des Verkehrsflusses, Warnung vor Gefahren, Sicherheit für Fußgänger, erkannt zu werden und das Vertrauen in andere Verkehrsteilnehmer (siehe Kapitel 3.1), nicht mehr erfüllt.

Für die erfolgreiche Einführung und die Akzeptanz von automatisierten Fahrzeugen ist das Vertrauen in die neuen Verkehrsteilnehmer eine unbedingt notwendige Bedingung [32]. Dies trifft v.a. für Gefahrensituationen zu, gilt jedoch auch für die alltägliche Interaktion mit Fahrradfahrern oder Fußgängern [10][98]. Domeyer et al. nennen in diesem Zusammenhang ein Phänomen namens Dread-Risk, welches die Angst vor Kontrollverlust bei sehr unwahrscheinlichen, aber verheerenden Ereignissen beschreibt [86]. Im Zusammenhang mit automatisierten Fahrzeugen kann hier beispielhaft eine Fehlfunktion dieser bei der Detektion eines Fußgängers mit tödlichen Folgen genannt werden. Nach Schaudt und Russell ist für die Steigerung des Vertrauens in automatisierte Fahrzeuge eine erfolgreiche Kommunikation essentiell, welche die informellen Zeichen der Fahrer ersetzt [89]. Auch das Kennzeichnen automatisierter Fahrzeuge bzw. Anzeige deren Fahrmodi kann einen entscheidenden Beitrag zur Akzeptanz dieser neuen Technologie darstellen und ein abweichendes Verhalten des Fahrers von der Fahrzeugbewegung bzw. Fahraufgabe erklären [88].

Basierend auf diesen Erkenntnissen empfiehlt die Ethik-Kommission des Bundesministeriums für Verkehr und digitale Infrastruktur, dass kritische Situationen beim automatisierten Fahren unbedingt vermieden werden sollen und dafür bspw. spezielle Signale für gefährdete Personen, z.B. Fußgänger oder Fahrradfahrer, eingesetzt werden können. Automatisierte Fahrzeuge sollen auch insbesondere Rücksicht auf schwächere Verkehrsteilnehmer nehmen, weshalb v.a. eine Kommunikation mit Fußgängern essentiell ist. Es soll auch eindeutig unterscheidbar sein, ob ein fahrerloses System genutzt wird oder der Fahrer die Verantwortung über die Fahraufgabe hat [9].


### **3.2.2. KOMMUNIKATIONSKONZEPTE AUTOMATISierter FAHRZEUGE**

Zur Kommunikation automatisierter Fahrzeuge mit anderen Verkehrsteilnehmern sind in der Literatur verschiedene Konzepte zu finden. Sie basieren auf unterschiedlichen Anzeigetechnologien und Methoden zur Interaktion mit Verkehrsteilnehmern, insbesondere Fußgängern.



### Kodierte Leuchten bzw. eindimensionale Leuchtenarrays

Eine technisch einfach umzusetzende visuelle Kommunikation kann mit Hilfe kodierter Leuchten bzw. einzelziger Leuchtenarrays erfolgen (vgl. Abbildung 3.1 (a)). Diese sind zumeist horizontal im Bereich der Frontscheibe des Fahrzeugs angebracht und verfügen über mindestens drei einzeln ansteuerbare Segmente [30][99][100]. Zur Anzeige verschiedener Botschaften werden die Leuchten häufig kodiert aktiviert, d.h. es leuchten nur einzelne Segmente des Arrays, oder mit Dynamiken, wie Pulsieren oder Blinken, versehen. Das Lauflicht bzw. die kodierte Leuchte ist dabei stets symmetrisch ausgeführt [30]. Das in Abbildung 3.1 (a) dargestellte Beispiel zeigt eine weiße Leuchte, wobei auch farbige Leuchtmittel eingesetzt werden, z.B. in Gelb oder Türkis [101]. Diese Farben werden in manchen Kommunikationskonzepten auch alternativ zur Kodierung der eindimensionalen Leuchtenarrays eingesetzt [17][102].



**Abbildung 3.1.:** Beispiel für eine kodierte Leuchte in Form eines eindimensionalen Leuchtenarrays (a) und Display zur Anzeige von Symbolen (b), nach [103]

### Displays und komplexere Anzeigemedien

Zweidimensionale bzw. mehrzeilige Leuchtenarrays und technologisch komplexere Anzeigemedien, wie z.B. Projektoren oder Displays, werden häufig für eine optische Kommunikation mit anderen Verkehrsteilnehmern untersucht.

Über die Anzeigeflächen werden grafisch aufbereitete Zeichen dargestellt, bspw. Symbole, Piktogramme und Texte, welche zumeist asymmetrisch dargestellt werden [28][29][104]. Neben weißen Lichtsignalen werden auch farbige Darstellungen in der Literatur beschrieben [28][105]. Ergänzend zur Anzeige von Symbolen und Texten am Fahrzeug, welche im Bereich der Leuchten oder des Kühlergrills erfolgen (vgl. Abbildung 3.1 (b)), sind in der Literatur alternativ Projektionen von Zeichen auf die Fahrbahnoberfläche oder in der Heckscheibe zu finden [106][107].

### **Weitere Kommunikationskonzepte**

Weitere Konzepte zur Kommunikation automatisierter Fahrzeuge mit anderen Verkehrsteilnehmern, v.a. mit Fußgängern, werden bspw. mittels Fahrzeugbewegung, akustischer Signale oder Mobilkommunikation mit mobilen Endgeräten umgesetzt. Hierbei sind v.a. die Fahrzeugbewegung bzw. die Veränderung der Fahrzeugdynamik und des Fahrzeugzustands häufig untersuchte Zeichen, da diese Art der Kommunikation bereits im Straßenverkehr anzutreffen ist [19][86]. Pennycooke sowie Mahadevan et al. beschreiben zusätzlich die Möglichkeit mittels akustischer Zeichen und Lautsprecher bzw. direkt mit dem mobilen Endgerät eines Fußgängers zu kommunizieren [17][108][109].

### **Bewertung der Konzepte zur Fahrzeug-Fußgänger-Kommunikation**

Wie bereits in Kapitel 3.1 beschrieben, bietet sich v.a. der visuelle Kanal für die Kommunikation im Straßenverkehr an. Akustische Signale sind dagegen fast ausschließlich zur Kommunikation in Gefahrensituationen geeignet. Deshalb soll diese Art der Zeichengebung nicht weiter betrachtet werden. Die Kommunikation mittels Fahrzeugdynamik und -zustand ist auch bei automatisierten Fahrzeugen stets zu beobachten, kann jedoch bei schlechten Sichtverhältnissen, z.B. Dunkelheit, kaum erkannt werden [4][5]. Ähnlich kann eine Projektion von Lichtzeichen auf die Fahrbahn in hellen Umgebungen nicht oder nur schwer erkannt werden, weshalb auch diese Möglichkeit der Kommunikation nicht universell einsetzbar ist [30]. Das Übertragen von Nachrichten vom Fahrzeug auf ein mobiles Endgerät, z.B. Smartphone, setzt voraus, dass der

Fußgänger ein solches besitzt und schnellen Zugriff darauf hat. Deshalb soll auch dieses Kommunikationskonzept nicht weiter verfolgt werden.

Generell sinnvoll ist die optische Kommunikation von Nachrichten mittels Leuchtenarrays und Displays. Kodierte oder farbige Leuchten sowie die Anzeige von Texten oder Symbolen spannen den möglichen Lösungsraum für die Fahrzeug-Fußgänger-Kommunikation auf und können sowohl in hellen als auch dunklen Umgebungen sicher erkannt werden. Diese Konzepte können wie Tagfahrlichter oder Positionsleuchten gestaltet und damit unter fast allen Umgebungsbedingungen sicher wahrgenommen werden. Eine Studie von Othersen et al. zeigt, dass Displays bzw. zweidimensionale Leuchtenarrays positiver bewertet werden als einfache Zeichen bzw. Fahrzeugdynamik. Dies hängt vermutlich mit dem Informationsgehalt pro verwendeten Zeichen zusammen [19].

### **3.3. INTENTIONSERKENNUNG IM STRASSENVERKEHR**

Durch die steigende Automatisierung von Fahrfunktionen und stetige Innovation im Bereich der Assistenz- und Sicherheitssysteme nimmt der Bedarf zu, menschliche Verhaltensweisen im Straßenverkehr zu erkennen. Dafür gibt es bereits in der Literatur verschiedene Anwendungsbeispiele. So beschäftigen sich viele Veröffentlichungen mit einer Intentionserkennung von Fußgängern mittels konventioneller Algorithmen und ANNs [110][111][112][113]. In [114] und [115] wird jeweils die Prädiktion von Verhaltensweisen anderer Verkehrsteilnehmer/Fahrer mittels RNNs und LSTMs beschrieben. Weiter werden in der Literatur Schätzungen der Fahrzeugtrajektorie untersucht, um bestehende Assistenzsysteme weiterzuentwickeln oder neue Anwendungen umzusetzen [116][117][118][119][120]. Hierfür werden in vier der recherchierten Quellen LSTM basierte Modelle verwendet. Weitere Funktionen sind die Prädiktion eines Fahrstreifenwechsels [121][122][123][124] oder eine allgemeine Manöverdetektion [125][126][127][128]. Während in diesen Arbeiten bei der Prädiktion des Fahrstreifenwechsels drei Forschergruppen konventionelle Algorithmen verwenden, kommen bei allgemeinen Manöverdetektionen ne-

ben einem Hidden Markov Model und einer Support Vector Machine zwei RNNs zum Einsatz.

Auch für die in dieser Arbeit vorgestellte Fahrerintentionserkennung eines Anhaltens an Zebrastreifen ist bereits ein Stand der Technik bekannt. Mittels der Hämoglobinkonzentration im zerebralen Kortex bestimmen Zhu et al. in einem Fahrsimulatorversuch die Intention des Fahrers anzuhalten [129]. Mit Hilfe eines ANNs lies sich dabei eine Treffergenauigkeit von 80,39 % erzielen. Tran et al. trainierten ein Hidden Markov Model (HMM) zur Erkennung von Anhalteintentionen und erreichten damit eine Treffergenauigkeit von ca. 90 % [124]. Im Gegensatz dazu verwenden Garcia Ortiz et al. zur Erkennung von Anhaltefällen an Verkehrsampeln ANNs [130]. Sie gehen von einem Prädiktionshorizont von 1 s bis 2 s aus und erreichen hier eine RPR/FPR von ungefähr 87 %/10 % bis 65 %/10 %.

### **3.4. ABSICHERUNG DATENBASIERTER ALGORITHMEN**

Sicherheit (Safety) ist einer der elementarsten Aspekte in der Automobilentwicklung. Durch zunehmende Integration von Funktionen in Fahrzeuge wächst deshalb der Bedarf an funktionaler Sicherheit sowie der Beweis deren Einhaltung [131]. Grundsätzlich wird die Sicherheit eines Systems durch die Abwesenheit von unzumutbaren Fehlern definiert [132][133] und funktionale Sicherheit als Abwesenheit unzumutbarer Fehler, welche durch Elektrik-/Elektronik-Systeme verursacht werden [132]. In sicherheitskritischen Anwendungen können Fehlerzustände zu materiellen Schäden, finanziellen Schäden oder sogar zur Gefährdung von Menschenleben führen [134]. Deshalb behandelt bspw. die Norm ISO 26262 die Sicherheit von Fahrzeugen. Hier ist die Einstufung eines Systems in ein Automotive Safety Integrity Level (ASIL) beschrieben, welches durch die drei Freiheitsgrade Wahrscheinlichkeit (probability), Kontrollierbarkeit (controllability) und Schwere (severity) in ASIL-A bis ASIL-D eingeteilt wird [135]. Die Sicherheitsanalyse ist davon abhängig, wie vollständig und genau ein System verstanden werden kann [136], wobei

bei steigender technologischer Komplexität von einem steigenden Risiko für systematische Fehler ausgegangen werden kann [131].

Übertragen auf die Softwareentwicklung und insbesondere auf Machine Learning basierte Algorithmen, ist es notwendig, Maßnahmen zum Erreichen von funktionaler Sicherheit umzusetzen [132][136]. Faria nennt hierfür bspw. die Verifikation und Interpretierbarkeit von Ergebnissen sowie eine konstruktive Sicherheit [136]. Die Verifikation kann u.a. durch geeignete Verfahren, Algorithmen und Testprotokolle erfolgen, wie z.B. von Hull et al. [137], Gehr et al. [138] oder Huang et al. [139] beschrieben. Eine Interpretierbarkeit ist bei komplexen Machine Learning Algorithmen häufig nicht sichergestellt [136], trotzdem sollten nach Varshney und Alemzadeh durch Menschen interpretierbare Modelle bevorzugt werden [133][140]. Eine konstruktive Sicherheit kann bspw. durch Berücksichtigung von Fehlerfällen beim Aufstellen einer Kostenfunktion erreicht werden [134][136]. Diese Fehlerfälle treten häufig in seltenen oder unerwarteten Situationen auf [133]. Dennoch ist es kaum möglich vorherzusagen, ob Machine Learning Algorithmen die richtigen Entscheidungen treffen werden, weil ihr Modell basierend auf bereitgestellten Daten erlernt wird [136].

Auch wenn Verfahren zur Verifikation oder Überwachung der Sicherheit von ANNs vorliegen [134, 137, 138, 139], sind v.a. tiefe neuronale Netze kaum interpretierbar und nahezu als Black-Box zu betrachten [133][136][140]. Die Anpassungsfähigkeit und Genauigkeit von ANNs wird von konventionellen Machine Learning Algorithmen nur selten übertroffen, doch präzisieren bzw. klassifizieren sie meistens auf Basis anderer Kriterien, als derer, die von den Entwicklern intendiert waren [141]. Trotzdem können einige Aspekte bei der Entwicklung neuronaler Netze berücksichtigt werden, um die funktionale Sicherheit zu erhöhen. So spielt vor allem der verwendete Datensatz eine entscheidende Rolle, welcher eine realitätsnahe Verteilung der Klassen und Situationen besitzen sollte [136]. Irrelevante Features sollten vor dem Training eines ANNs auf jeden Fall aus dem Datensatz entfernt werden [133]. Darüber hinaus sollte der Trainingsdatensatz ständig erweitert und verbessert werden, um ein optimales Modell für die jeweilige Aufgabe zu finden [142]. Weiter hängt die Sicherheit von der Modellauswahl, z.B. Anzahl, Größe und Aufbau der Schichten, und den verwendeten Features bzw. deren Vorverarbeitung

ab [136][140], wobei auch hier das No Free Lunch Theorem gilt, nachdem es keine perfekte Lösung für alle Problemstellungen gibt [41]. Als letztes weißt Al-Khourny darauf hin, dass end-to-end Ansätze als nicht interpretierbar gelten und daher eine Einteilung in logische Unteraufgaben erfolgen sollte [134]. Dies entspricht dem Prinzip Divide-and-Conquer (teile und herrsche) [143].

### **3.5. VERGLEICH VON NEURONALEN NETZEN MIT KONVENTIONELLEN ALGORITHMEN**

ANNs finden mittlerweile häufig bei der Analyse und Prädiktion von Zeitreihen Anwendung, wobei konventionelle Algorithmen diese Aufgaben schon lange bearbeiten [39][70][144]. Zu den konventionellen Algorithmen zählen bspw. das Kalman Filter, HMMs, Auto Regressive-Moving Average (ARMA) und Auto Regressive Integrated Moving Average (ARIMA) [51][70][144].

Für Anwendungen mit sequentiellen Daten oder Eingangsgrößen sind in der Literatur viele Vergleiche zwischen konventionellen Algorithmen und ANNs zu finden. So übertreffen neuronale Netze den ARIMA Algorithmus zur Vorhersage von Wind [145], Hypothekbelastung, Passagierzahlen [146] oder für den Wechselkurs von Devisen [51]. Für diese Anwendung konnten ANNs auch höhere Genauigkeiten als ARMA und Box-Jenkins Algorithmen erreichen, weil diese im Gegensatz zu ANNs lediglich lineare Zusammenhänge annehmen [51]. Kim zeigt als Vorteil von LSTMs auf, dass diese im Gegensatz zu Support Vector Machines (SVMs) und ARIMA nicht nur wenige (ca. 5), sondern viele (bis zu 1000 [71]) Sequenzschritte der Vergangenheit einbeziehen können [146]. Einen Vergleich zu SVMs sowie Gaussian Mixture Models (GMMs) und Conditional Random Fields (CRFs) ziehen auch Salehinejad und Sankar mit dem Ergebnis, dass RNNs zeitliche Zusammenhänge, z.B. für Textanalyse oder Audioverarbeitung, besser modellieren können [72]. DeCruyenaere und Hafez verglichen bereits 1992 ein Kalman Filter mit RNNs wobei die neuronalen Netze das konventionelle Filter übertrafen [147]. Gers beschreibt in seiner Arbeit, dass LSTMs konventionelle Algorithmen wie Ran-

dom Guessing, Symbolic Grammar Learning Algorithm (SGLA) und HMMs für verrauschte Signale mit variabler Sequenzlänge übertreffen [70]. RNNs und somit auch LSTMs können, wie oben beschrieben, Daten mit variabler Eingangslänge verarbeiten, was mit konventionellen Ansätzen nicht oder nur begrenzt möglich ist (siehe Kapitel 2.5). Umematsu et al. zeigen, dass LSTMs Modelle mit linearer Regression und SVMs für die Prädiktion von Stresslevel übertreffen [148].

RNNs können jedes dynamische System modellieren und werden daher für verschiedenste Anwendungen eingesetzt, z.B. Textanalyse, Spracherkennung, -synthese, Audioanalyse, etc. [72]. So stellen LSTMs heute in unterschiedlichen Anwendungen den Stand der Technik dar und gelten als Maßstab für eine korrekte Prädiktion, wie z.B. bei Nutzungsverhalten von Mobilitätsdiensten [149], Manöverprädiktion von Fahrzeugen an Kreuzungen [150] oder Benchmarkdatensätze [151]. Einschränkend gilt jedoch auch hier, dass obwohl ANNs, insbesondere RNNs gegenüber konventionellen Algorithmen signifikante Vorteile aufweisen, sie keine perfekte Lösung für alle Probleme darstellen und das No Free Lunch Theorem berücksichtigt werden muss [41].

---

## KAPITEL 4

# LICHTBASIERTE FAHRZEUG- FUSSGÄNGER-KOMMUNIKATION

Dieses Kapitel beschreibt Untersuchungen zur lichtbasierten Fahrzeug-Fußgänger-Kommunikation, mit der sowohl „manuelle“ als auch automatisierte Fahrzeuge in Zukunft mit anderen Verkehrsteilnehmern kommunizieren können. Hierfür wird nach der Definition der Anforderungen an ein solches System eine Voruntersuchung zur Intuitivität von Symbolen beschrieben. Anschließend folgt die Analyse der unterstützenden Wirkung von Farben auf die Verständlichkeit von Symbolen in einer Probandenstudie und eine abschließende Untersuchungskritik.

## 4.1. ANFORDERUNGEN AN DIE KOMMUNIKATION MIT ANDEREN VERKEHRSTEILNEHMERN

Das Dekodieren des empfangenen Signals und Verstehen der Nachricht setzt sich beim Empfänger aus zwei Komponenten zusammen. Zuerst muss der adressierte Verkehrsteilnehmer das Zeichen erkennen, um es anschließend funktional zu deuten [152]. Unter der Voraussetzung, dass das Zeichen richtig erkannt werden kann, müssen beide Kommunikationspartner der Nachricht die gleiche Bedeutung zuordnen. Bei der Anzeige von Text mittels Displays oder Leuchtenarrays am Fahrzeug bedeutet das, dass alle adressierten Kommunikationspartner lesen können und die gleiche Sprache verstehen müssen [21]. Deshalb und weil Textnachrichten, abgesehen von kurzen Ausdrücken wie „Stopp“, sehr langsam erkannt und verstanden werden, wird diese Art

---



der Kommunikation im Straßenverkehr und für automatisierte Fahrzeuge nur selten eingesetzt [153].

### **Relevante Nachrichten für die Fahrzeug-Fußgänger-Kommunikation**

In der Literatur finden sich verschiedenste Nachrichten, welche mit lichtbasierten Kommunikationsmitteln anderen Verkehrsteilnehmern kommuniziert bzw. signalisiert werden. Häufig wird die Notwendigkeit für eine Statusanzeige des Fahrmodus genannt, ob ein Fahrzeug automatisiert oder „manuell“ betrieben wird [9][30][31][154]. Dies ist, wie in Kapitel 3.2.1 beschrieben, besonders notwendig, um eindeutig die Verantwortlichkeit des Fahrzeugs für die Fahraufgabe anzuzeigen, Vertrauen aufzubauen und Akzeptanz für die neue Technologie zu schaffen.

Außerdem wird besonders eine Kommunikation mit Fußgängern empfohlen. Diese Interaktion mit schwächeren Verkehrsteilnehmern ist schon im heutigen Straßenverkehr essentiell (siehe Kapitel 3.1). Auch hier spielt das Vertrauen in andere Verkehrsteilnehmer eine entscheidende Rolle, wobei auch das Vermeiden bzw. das Minimieren von Gefahren Gründe für eine Kommunikation sind, z.B. wenn sich die Trajektorien von Fahrzeugen und Fußgängern überschneiden und sich dadurch das Unfallrisiko erhöht. Deshalb liegt das Anzeigen von Zeichen für das Erkennen eines Fußgängers [10][30], Empfehlung die Straße nicht zu überqueren [28][30] oder Vorfahrt gewähren [19][28][30][92] nahe. Die Empfehlung, die Straße nicht zu überqueren, könnte dabei durch das Fehlen einer Kommunikation implizit dargestellt werden. Wenn also kein Zeichen angezeigt wird, welches dem Fußgänger eine positive Nachricht sendet, kann er davon ausgehen, dass das Gegenteil zutrifft und er in diesem Fall die Straße nicht überqueren sollte. Das Vorfahrt gewähren und eine Kommunikation der Anfahrintention kann sowohl an Fußgänger, als auch an motorisierte Verkehrsteilnehmer adressiert sein [30][31]. Vorfahrt gewähren für Fußgänger soll für die nachfolgenden Kapitel als eine Botschaft an Fußgänger definiert werden, bei der das Fahrzeug dem Fußgänger die Vorfahrt bzw. den Vorrang gewährt.

In dieser Arbeit werden daher v.a. die Nachrichten „das Fahrzeug befindet sich in einem automatisierten Fahrmodus“, „das Fahrzeug hat einen Fußgänger erkannt“, „das Fahrzeug lässt einen Fußgänger überqueren“ und „das

Fahrzeug empfiehlt die Straße nicht zu überqueren“ betrachtet. Diese Nachrichten werden benötigt, wenn ein Fußgänger die Straße überqueren möchte und sich gleichzeitig ein Fahrzeug nähert. Eine beispielhafte Situation kann ein Zebrastreifen oder ein anderer Fußgängerüberweg sein.

### **Anforderung an die Verständlichkeit und Aussagekraft von Zeichen**

Um eine sichere Fahrzeug-Fußgänger-Kommunikation entwickeln zu können, müssen Anforderungen an die dafür verwendeten Zeichen gestellt werden. Diese unterscheiden sich neben ihrem Design auch in Aussagekraft (meaningfulness) und Verständlichkeit (understandability) [155][156]. Um diese Metriken zu untersuchen und zu bewerten, können Probandenstudien durchgeführt werden, welche als Indikator dienen, wie gut die Zeichen im Straßenverkehr verstanden werden. Die Erkennungsrate (ER) gibt in diesem Zusammenhang das Verhältnis zwischen der Anzahl der korrekten Antworten  $N_k$  und der Gesamtzahl der Bewertungen  $N_a$  an [104]. Die Erkennungsrate kann ähnlich dem Genauigkeitsmaß Accuracy (siehe Gleichung 2.3) nach folgender Berechnungsvorschrift bestimmt werden [44]:

$$ER = \frac{N_k}{N_a} \quad (4.1)$$

Tijus et al. verweisen in [21] auf die Norm ISO 9186-1989, nach der Symbole genau dann verständlich sind, wenn mindestens 67 % der befragten Personen das Zeichen voll oder zumindest teilweise richtig interpretieren. Deshalb soll die Erkennungsrate aller Zeichen für die Fahrzeug-Fußgänger-Kommunikation dieses Kriterium erfüllen. In der exploratorischen Forschung, die sich u.a. damit beschäftigt, wie aussagekräftig Symbole sind oder mit welcher Selbstsicherheit Probanden diese bewerten, ist es ausreichend, wenn die Bewertungen der Zeichen durchschnittlich in der besseren Hälfte der Bewertungsskala liegen. Diese Festlegung ist an die psychophysische Schwellenmessung nach Bortz und Döring angelehnt, bei welcher ein Proband mindestens 50 % der Reize korrekt benennen muss [157]. Diese Anforderung soll deshalb v.a. für die Aussagekraft der Zeichen erfüllt werden.

Die Anforderungen an die Verständlichkeit und Aussagekraft von Zeichen muss v.a. wegen den potentiell negativen Auswirkungen einer falsch ver-

standenen Kommunikation im Straßenverkehr (siehe Kapitel 3.1) kritisch hinterfragt werden. So ist in der ANSI Z535, 1987 Norm eine minimale Erkennungsrate von 85 % definiert, welche um 18 % höher liegt als die Schwelle der oben genannten ISO Norm. Der Definition in der ANSI Z535 folgend kann die oben aufgestellte Anforderung zur Folge haben, dass trotz Erfüllen der Anforderung der ISO Norm, die am Fahrzeug angezeigten Zeichen nicht ausreichend verständlich für eine Kommunikation im Straßenverkehr sind und dass das Vertrauen in die Kommunikationspartner sinkt bzw. der angestrebte Sicherheitsgewinn nicht erreicht wird.

## **4.2. VORUNTERSUCHUNG ZUR INTUITIVITÄT VON ZEICHEN UND DYNAMIKEN**

Eine Voruntersuchung zur Intuitivität von Symbolen und Dynamiken für eine Fahrzeug-Fußgänger-Kommunikation über Displays und Leuchtenarrays soll in einer Probandenstudie durchgeführt werden. Ziel dieses exploratorischen Ansatzes ist es, verschiedene Zeichen unterschiedlicher Komplexität und Dynamik bzgl. deren Verständlichkeit und Erkennungszeiten zu evaluieren. Damit soll eine Vorauswahl der Zeichen für die Kommunikation automatisierter Fahrzeuge zur weiteren Untersuchung in einer Onlinestudie (siehe Kapitel 4.3) getroffen werden bzw. welche gemeinsamen Merkmale verständliche und aussagekräftige Symbole aufweisen.

Die nachfolgend vorgestellten Ergebnisse beruhen teilweise auf drei Veröffentlichungen [104][158][159], die im Rahmen dieser Arbeit erstellt wurden.

### **4.2.1. AUFBAU DER VORUNTERSUCHUNG**

Für die Voruntersuchung verschiedener Zeichen einer Fahrzeug-Fußgänger-Kommunikation werden neben Symbolen auch abstraktere Zeichen untersucht (siehe Abbildung 4.1). Dies sind Zeichen oder stark vereinfachte Symbole, welche in ein- und zweidimensionalen Leuchtenarrays ohne stilistischen Bezug

zu physischen Objekten dargestellt werden können (vgl. z.B. Symbole 2, 3, 5 in Abbildung 4.1). Es werden sowohl statische als auch dynamische Zeichen evaluiert, z.B. sequentielles Aufbauen eines Symbols oder ein lineares Verschieben und Drehen der Zeichen (siehe blaue Pfeile in Abbildung 4.1), da bewegte Zeichen nach [3] und [107] mehr Aufmerksamkeit auf sich ziehen als unbewegte. Die Zeichen, die speziell für ein- und zweidimensionale Leuchtenarrays entwickelt werden, setzen sich aus einer oder mehreren rechteckigen Formen zusammen, z.B. Symbol 2, 4 oder 5. Die ausgewählten Symbole bestehen aus bekannten Zeichen aus dem Straßenverkehr (z.B. Symbol 18 oder 27), aus Icons aus dem Fahrzeuginnenraum abgeleiteter Darstellungen (z.B. Symbol 9 oder 20), stilisierten Verkehrszeichen (z.B. Symbol 10 oder 23) oder Kombination dieser (z.B. Symbol 6 oder 20). Neben Zeichen, die eindeutig für eine Fahrzeug-Fußgänger-Kommunikation an Fußgängerüberwegen ausgewählt werden (z.B. Symbol 18 oder 27), finden sich, wie im realen Straßenverkehr auch, Zeichen in der Auswahl, welche die Probanden ablenken können und eine andere Nachricht visualisieren (z.B. Symbol 7 oder 29). Alle Zeichen werden nach Möglichkeit nach den Leitlinien für eine verständliche und aussagekräftige Gestaltung von Zeichen und Symbolen erstellt bzw. ausgewählt (vgl. Kapitel 2.1). Außerdem werden alle Zeichen achromatisch, d.h. weiß auf dunklem Hintergrund und ohne Farben, dargestellt, um in dieser Voruntersuchung weniger abhängige Variablen gleichzeitig zu evaluieren. In Kapitel 4.3 wird im Rahmen einer Onlinestudie die Farbe als weitere Variation der lichtbasierten Kommunikation im Straßenverkehr untersucht.

Die im Lichtassistentenzentrum der AUDI AG durchgeführte Probandenstudie gliedert sich in vier Hauptteile und dauert max. 45 Minuten. Zu Beginn wird jeder der 35 Teilnehmer (vgl. Kapitel 4.2.2) einzeln in die Studie eingewiesen, der Ablauf erklärt und offene Fragen beantwortet. Außerdem werden demographische Daten wie Alter, Sehfähigkeit, Geschlecht und Regelmäßigkeit der Teilnahme am Straßenverkehr aufgenommen. Die Probanden werden gebeten, sich während der gesamten Studie vorzustellen, die dargebotenen Zeichen im Straßenverkehr anzutreffen. Alle Antworten und Anmerkungen werden während der gesamten Untersuchung durch den Versuchsleiter dokumentiert. Das Studiendesign ist an die Arbeiten von Merten [3] sowie Lagström und Lundgren [30] angelehnt.

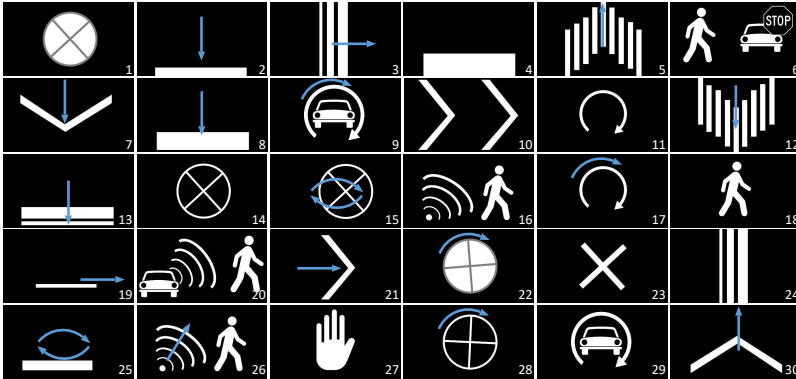


Abbildung 4.1.: In der Voruntersuchung evaluierte Zeichen [104]

Für die ersten beiden Teile der Studie steht der Proband in  $10\text{ m}$  Abstand zu einem Versuchsfahrzeug, an dessen Front zwei Displays mit den Abmessungen  $30\text{ cm} \times 23\text{ cm}$  unterhalb der Scheinwerfer angebracht sind. Die Studienteilnehmer werden aufgefordert, die auf beiden Displays gezeigten Zeichen zu betrachten und Ihnen eine Bedeutung zuzuordnen, bevor sie mit dem nächsten Symbol fortfahren. Um die Zeit für das Deuten der Zeichen zu messen, kann jeder Teilnehmer über eine Fernbedienung selbst zur nächsten Darstellung wechseln. Zwischen den verschiedenen Symbolen sind eindeutig gekennzeichnete Pausen, in denen der Proband seine Interpretation der Bedeutung beschreiben kann.

Der Ablauf im ersten und zweiten Teil der Studie unterscheidet sich nur wenig. Im ersten Teil hat jeder Proband maximal  $10\text{ s}$  für das freie Deuten ohne vorgegebene Antworten, wobei im zweiten Teil für die Wahl aus sieben vorgegebenen Antwortmöglichkeiten maximal  $5\text{ s}$  zur Verfügung stehen. Diese maximalen Antwortzeitdauern der Probanden wurden in einer Expertengruppe vor der Durchführung der Voruntersuchung festgelegt. Die vorgegebenen Antworten sind (1) „Fahrzeug steht“, (2) „Fahrzeug beschleunigt“, (3) „Fahrzeug brems“, (4) „Fahrzeug biegt ab“, (5) „Fahrzeug hat Fußgänger erkannt“, (6) „Fußgänger darf gehen“ und (7) „Fußgänger sollte/muss stehen bleiben“. Kann der Proband dem gezeigten Zeichen keine dieser Antworten zuordnen, so wird nach  $5\text{ s}$  ohne Antwort mit dem nächsten Zeichen fortgefahren.

Im zweiten Abschnitt der Studie finden zwei Messwiederholungen mit vorgegebenen Antworten statt. Den Teilnehmern werden alle Zeichen in einer einmalig randomisierten Reihenfolge dargeboten.

Im dritten Teil der Studie werden den Probanden alle Zeichen auf einem Notebook gezeigt und jeweils die folgenden drei Aussagen genannt: „Das gezeigte Symbol empfinde ich als aussagekräftig oder intuitiv“, „Das gezeigte Symbol ist gut zu erkennen“ und „Ich verstehe, dass das Fahrzeug mit mir kommuniziert“. Diese werden von den Probanden subjektiv auf einer sechsstufigen Likert-Skala bewertet, welche mit ihrer äquidistanten Skaleneinteilung generell für die Evaluation der Zustimmung von Probanden zu einer bestimmten Frage gewählt wird [160]. Durch die Verwendung der sechs Stufen „1: trifft voll und ganz zu“ bis „6: trifft überhaupt nicht zu“ wird die Tendenz zur Mitte vermieden. Eine feinere Abstufung bringt nach Jonkisz et al. keinen Informationsgewinn [161].

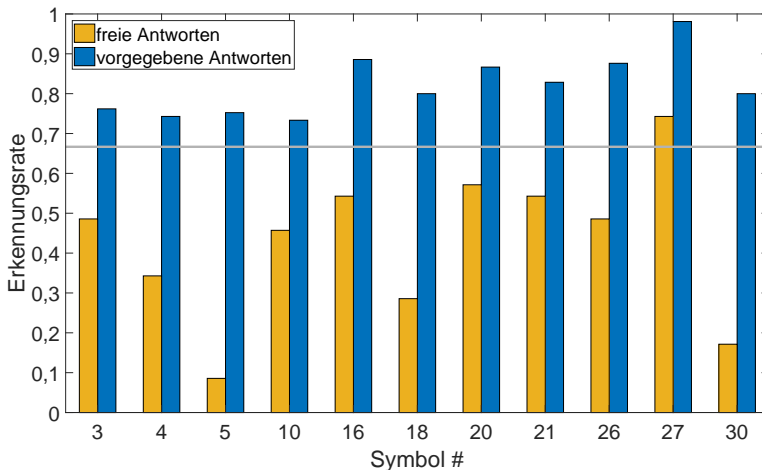
Im vierten Hauptteil der Probandenstudie werden den Probanden wie in Teil drei alle Symbole gezeigt und über Ja-/Nein-Fragen nochmals die Bedeutung der Zeichen abgefragt. Zu jedem Symbol soll der Proband entscheiden, ob Bedeutung (1) bis (7) dem Zeichen zugeordnet werden kann. Dafür muss er zu jedem Zeichen sieben Ja-/Nein-Fragen beantworten. Die Teilnehmer haben dabei auch stets die Möglichkeit „Ich weiß nicht“ als Antwort zu geben.

#### **4.2.2. AUSWERTUNG UND DISKUSSION DER ERGEBNISSE AUS DER VORUNTERSUCHUNG**

Insgesamt nehmen 35 Personen mit einem Durchschnittsalter von 28,2 Jahren (Standardabweichung: 8,6 Jahre; Median: 26 Jahre) teil. Die vier weiblichen und 31 männlichen Probanden besitzen eine normale oder korrigierte Sehfähigkeit, wobei zwei Teilnehmer eine geringe Kurzsichtigkeit aufweisen ( $-0,25\text{ dpt}$  und  $-0,5\text{ dpt}$ ). Zwei der männlichen Probanden haben außerdem eine Farbfehlsichtigkeit (Deuteranopie bzw. Protanopie), was für die Versuchsdurchführung aufgrund der achromatischen Darstellung keinen Einfluss auf die Ergebnisse hat. 33 Teilnehmer (ca. 94,3%) geben an häufig (mehr als

viermal pro Woche) oder gelegentlich (mehr als einmal pro Woche) selbst ein Kraftfahrzeug zu führen. Die vom Hersteller der Displays angegebene Leuchtdichte von  $315 \text{ cdm}^{-2}$  wird von allen Probanden als ausreichend hell bewertet.

Aus den ersten beiden Teilen der Studie werden für die freien und vorgegebenen Antworten die Erkennungsraten nach Gleichung 4.1 bestimmt (siehe Anhang A.1, Abbildung A.1). Als korrekte Bedeutung der Zeichen wird das Ergebnis aus dem Mehrheitsvotum der Antworten aus Teil zwei der Studie verwendet, um eine möglicherweise falsche Interpretation des Versuchsleiters auszuschließen. Die Erkennungsraten der elf Zeichen, welche die in der Norm ISO 9186-1989 definierten Schwelle von 67 % übertreffen (siehe Kapitel 4.1), sind in Abbildung 4.2 dargestellt. Lediglich das Symbol 27 erfüllt diese Bedingung sowohl für die freien (74,3%) als auch für die vorgegebenen Antworten (98,1%) und kann damit als intuitiv und verständlich bezeichnet werden. Die anderen Zeichen erreichen Erkennungsraten zwischen 8,6% und 57,1% für die freien und 73,3% bis 88,6% für die vorgegebenen Antworten.



**Abbildung 4.2.:** Mittlere Erkennungsraten ausgewählter Symbole für freie und vorgegebene Antwortmöglichkeiten

Die Ergebnisse der Erkennungsraten im ersten und zweiten Teil der Voruntersuchung zeigen, dass auch im Straßenverkehr etablierte Symbole (z.B. Symbol 18), ohne die sonst typische Farbe, in dem ungewohnten Anzeigekonzept nicht intuitiv gedeutet werden können. Dies stimmt mit den Ergebnissen von Tijus et al. [21] und Dewar [24] überein. Außerdem bestätigen Ergebnisse von Othersen et al. [19], Kriefft et al. [162] und Budanow et al. [29], dass v.a. einfache, unbekannte Zeichen nicht intuitiv erkannt werden. Die hohen Erkennungsraten im zweiten Hauptteil der Probandenstudie weisen darauf hin, dass die Bedeutung der Zeichen gelernt und damit die Verständlichkeit gesteigert werden kann (siehe auch Kapitel 2.1.1). Dies ist ähnlich der zukünftigen Situation im Straßenverkehr, in welcher Fußgänger und andere Verkehrsteilnehmer lediglich eine begrenzte Anzahl von Möglichkeiten des weiteren Situationsverlaufs vermuten müssen und sich zwischen diesen entscheiden können.

Bei den freien Antworten im ersten Teil der Studie werden in insgesamt 77,4 % falsche Deutungen der Zeichen wiedergegeben, welche sich zwischen den Probanden teilweise erheblich unterscheiden. Insbesondere die Deutung vertikaler Dynamiken fällt den Teilnehmern schwer. Diese werden fast genauso häufig konträr als „Fahrzeug beschleunigt“ und „Fahrzeug bremst“ interpretiert, wie sie richtig gedeutet werden. Die Probanden vermuten in manchen Fällen widersprüchliche Adressaten der Kommunikation, z.B. „ein sich annäherndes Fahrzeug soll stoppen“ und „ich bzw. Fußgänger soll stoppen“ (bspw. bei Symbole 6 oder 23). Besonders bei abstrakten Symbolen oder Zeichen linearer Leuchtenarrays können die Probanden, in der Zeit in der dieses Zeichen angezeigt wird, keine Bedeutung oder eine mögliche Verkehrssituationen nennen.

Diese Ergebnisse decken sich weitgehend mit der Bewertung der Aussagekraft der Zeichen in Teil drei. Für die Zeichen, welche die geforderte Erkennungsrate von 67 % erreichen (siehe Abbildung 4.2), ergeben sich die in Tabelle 4.1 aufgeführten mittleren Bewertungen der Aussagekraft. Die Bewertungen von insgesamt 18 Zeichen liegen in der besseren Hälfte der Likert-Skala und erfüllen damit das in Kapitel 4.1 beschriebene Kriterium für die Verständlichkeit von Zeichen zur Fahrzeug-Fußgänger-Kommunikation. Am aussagekräftigsten ist das Symbol 27 mit einem Mittelwert von 1,1, gefolgt von dem aus dem



Straßenverkehr bekannten Symbol 18 und einem dynamischen Richtungspfeil (Zeichen 21) mit einer Bewertung von 1,9.

**Tabelle 4.1.:**

Durchschnittliche Bewertung der Aussagekraft ausgewählter Symbole

Symbol	3	4	5	10	16	18	20	21	26	27	30
Bewertung	3,1	3,3	2,3	2,2	2,1	1,9	2,1	1,9	2,1	1,1	2,4

Aus den Antworten der Ja-/Nein-Fragen im vierten Hauptteil der Voruntersuchung lassen sich ebenfalls Erkennungsraten bestimmen. Im Gegensatz zu Teil zwei werden hier die Zeichen mit Hilfe eines Notebooks in einer Arbeitsplatzumgebung dargestellt. Die daraus resultierenden Erkennungsraten unterscheiden sich kaum von denen der im zweiten Teil der Studie ermittelten. Im zweiten Teil der Studie sollten die Probanden am Fahrzeug dargestellte Zeichen in einem realistischeren Versuchsaufbau deuten. Trotzdem ergibt sich ein eindeutig linearen Zusammenhang durch Berechnung des Korrelationskoeffizienten  $r = 0,967$  zwischen den Erkennungsraten im Teil zwei  $ER_2$  und vier  $ER_4$  [160]:

$$r = \frac{cov(ER_2, ER_4)}{\sigma(ER_2)\sigma(ER_4)} \quad (4.2)$$

mit der Kovarianz der beiden Erkennungsraten

$$cov(ER_2, ER_4) = \frac{\sum_{i=1}^{N_Z} (ER_{2,i} - \overline{ER_2})(ER_{4,i} - \overline{ER_4})}{N_Z - 1} \quad (4.3)$$

wobei  $\sigma(ER_2)$  und  $\sigma(ER_4)$  die Standardabweichungen der Erkennungsraten,  $\overline{ER_2}$  und  $\overline{ER_4}$  die Mittelwerte der Erkennungsraten und  $N_Z = 30$  die Anzahl der Zeichen angeben [160]. Dies weist für zukünftige Untersuchungen darauf hin, dass der Versuchsaufbau kaum Einfluss auf die Deutung der Zeichen hat und Studien mit Hilfe von Notebooks und in einer Arbeitsplatzumgebungen durchgeführt werden können.

In Teil eins der Studie werden die Zeichen im Durchschnitt in 6,64 s (Standardabweichung: 1,57 s; Median: 6,83 s) intuitiv gedeutet, wobei Symbol 27 mit durchschnittlich 2,72 s die kürzeste Erkennungszeit aufweist und das Zeichen 25 von 30 Probanden überhaupt nicht erkannt wird. Für letzteres ergibt sich

deshalb eine Zeit von 9,27 s. Die Zeiten für die Deutung der Zeichen mit vorgegebenen Antworten beträgt durchschnittlich 2,88 s (Standardabweichung: 0,75 s; Median: 2,84 s). Die schnellste durchschnittliche Zuordnung erfolgt wieder bei Symbol 27 und beträgt 1,49 s, die längste mittlere Dauer wird bei Zeichen 25 mit 4,43 s gemessen. In den Fällen, in denen die Probanden keine Antwort in der maximal vorgegebenen Zeit geben können, wird diese (10 s bzw. 5 s) als Antwortzeit gewertet.

Dies zeigt, dass die Zeit, welche benötigt wird, um ein Zeichen zu deuten, bei vorgegebenen Antworten wesentlich niedriger ausfällt als für freie Antworten. In beiden Fällen ist die durchschnittliche Zeit jedoch sehr hoch, besonders im Hinblick auf schnelle Entscheidungen, die häufig im Straßenverkehr notwendig sind. Der Vergleich des durchschnittlichen Wertes der Erkennungszeit mit dem des intuitiven Symbols 27 zeigt, dass ein verständliches Zeichendesign unbedingt notwendig ist und die Intuitivität der Zeichen eine entscheidende Rolle spielt. Auch hier ist wegen der um den Faktor 2,3 besseren Ergebnisse in Teil zwei der Studie davon auszugehen, dass eine hohe Intuitivität oder vielmehr das Lernen der Zeichen unbedingt notwendig sind.

Für weitere Untersuchungen und für zukünftige Kommunikationskonzepte sind vor allem Symbole 18 und 20 relevant (siehe Abbildung 4.3). Das Symbol 18 ist das mit der höchsten Erkennungsrate für die Bedeutung „Fußgänger darf gehen“. Dieses Zeichen ist intuitiv nicht verständlich, aber bei vorgegebenen Antworten erfüllt es die in Kapitel 4.1 genannte Anforderungen der Norm ISO 9186-1989. Gleiches gilt für Symbol 20 mit der Nachricht „Fahrzeug hat Fußgänger erkannt“. Dieses Zeichen wird von Probanden, möglicherweise wegen der Darstellung eines Fahrzeugs als Bestandteil des Symbols, bei den freien Antworten zuverlässiger richtig gedeutet als die Symbole 16 und 26. Für diese beiden wird als Falschantwort mehrmals „WLAN für Fußgänger“ genannt, während Zeichen 20 durch den Fahrzeugbezug zu 57,1 % sinnvoll interpretiert wird. Symbol 27 erfüllt die in Kapitel 4.1 aufgestellten Anforderungen an Zeichen zur Fahrzeug-Fußgänger-Kommunikation und kann daher in ein Kommunikationskonzept integriert werden. Dieses Zeichen kann alternativ durch eine implizite Kommunikation eines nicht vorhandenen Symbols ersetzt werden (siehe Kapitel 4.1). Außerdem zeigen die Ergebnisse, insbesondere die Verständlichkeit der Linien- und Rechtecksymbole, deutlich, dass

eine Kommunikation automatisierter Fahrzeug nicht über eindimensionale Leuchtenarrays erfolgen sollte.



**Abbildung 4.3.:** Ausgewählte Symbole für weitere Untersuchungen und Kommunikationskonzepte, nach [104]

#### 4.3. UNTERSUCHUNG DER UNTERSTÜTZENDEN WIRKUNG VON FARBEN AUF DIE VERSTÄNDLICHKEIT VON SYMBOLEN

Im vorausgehenden Kapitel 4.2 wird eine Probandenstudie zur Untersuchung der Intuitivität von weißen Zeichen und Dynamiken beschrieben. Die beiden wichtigsten Ergebnisse sind, dass Symbole verständlicher und aussagekräftiger sind als abstrakte Zeichen, z.B. für eindimensionale Leuchtenarrays, diese aber trotzdem nicht intuitiv interpretiert werden können. Lediglich Symbol 27 ist intuitiv verständlich.

Deshalb wird im Rahmen dieses Kapitels eine Untersuchung beschrieben, welche die unterstützende Wirkung von Farben auf die Verständlichkeit von Symbolen evaluiert. Dazu werden bereits in der Voruntersuchung ausgewählte Zeichen (siehe Kapitel 4.2) durch weitere Symbole ergänzt und als Bewertungsbasis nochmals bzgl. deren Verständlichkeit und Aussagekraft untersucht. Anschließend werden die Zeichen mit verschiedenen Farben kombiniert, um die unterstützende Wirkung für eine Fahrzeug-Fußgänger-Kommunikation abzutesten.

Die in diesem Kapitel vorgestellten Ergebnisse beruhen teilweise auf den Veröffentlichungen von Marichalar Quezada und Auburger [163] sowie Reschke et al. [35][105][164][165], die im Rahmen dieser Arbeit entstanden. Aufbau

und Durchführung der Onlinestudie erfolgten im Rahmen der Projektarbeit von Marichalar Quezada und Auburger.

#### 4.3.1. VORBEREITUNG DER ONLINESTUDIE

Die Untersuchung der unterstützenden Wirkung von Farben auf die Verständlichkeit von Symbolen wird mit Hilfe einer Onlinestudie durchgeführt. Durch den Einsatz von Onlinestudien ist es möglich, große und diverse Stichproben zu erhalten, sowie auf einen internationalen Probandenpool zugreifen zu können. Diese Art der Probandenakquisition ist v.a. im Bereich der Psychologie und Sozialwissenschaften anzutreffen und hat sich z.B. bei Fridman et al. zur Untersuchung einer Fahrzeug-Fußgänger-Kommunikation bewährt [28]. Wie in Kapitel 4.2.2 beschrieben, ist die Untersuchung der Verständlichkeit von Zeichen an PCs vergleichbar mit der Evaluation realistischer Versuchsaufbauten.

Die Onlinestudie untersucht die Intuitivität und Verständlichkeit von Farben und Symbolen zur visuellen Kennzeichnung eines automatisierten Fahrmodus (Automated Driving, AD), Darstellung des Vorfahrt-gewährens für Fußgänger (Crossing of a Pedestrian, C) und Erkennen eines Fußgängers (Detection, D). Othersen et al. empfehlen, für unkritische Situationen Ich-Botschaften und für kritische Situationen Aufforderungen einzusetzen [19]. Dieser Empfehlung folgt die Formulierung der Bedeutung der ausgewählten Symbole. So ist der Fahrmodus unkritisch und wird daher als Information über das Fahrzeug formuliert. Ein Vorfahrt gewähren mit direkter Adressierung des Fußgängers ist eher kritisch und wird daher als Aufforderung umgesetzt, während das Erkennen des Fußgängers neutral formuliert ist.

#### **Symbolauswahl**

Für jede der drei ausgewählten Nachrichten werden jeweils drei Symbole ausgewählt und in der Onlinestudie untersucht (siehe Abbildung 4.4).

Der automatisierte Fahrmodus wird wahlweise mittels des Audi-spezifischen „Audi-AI“ Logos (Audi Intelligence, AD1), eines Symbols für ein intelligentes



**Abbildung 4.4.:** Symbole und Farben für die Onlinestudie [105]

Fahrzeug (AD2) oder mittels eines stilisiert dargestellten Lenkrads mit Händen, die das Lenkrad nicht berühren (AD3), dargestellt. Das Audi-AI Logo wird für Show- und Konzeptfahrzeuge der AUDI AG als Markenname eingesetzt, um deren automatisierte und intelligente Fahrfunktionen hervorzuheben und eignet sich daher als etabliertes Markenzeichen [166]. Das Symbol AD2 stellt ein Fahrzeug mit abstrakten Schaltungs- bzw. Platinenlayout dar und soll damit die Verbindung zur hochtechnologischen, automatisierten Fahrfunktion des Fahrzeugs schaffen. Dies ist an das Konzept von Hyundai angelehnt, bei dem ein grünes Blatt eine Metapher für neue Antriebstechnologien ist, wie z.B. Flüssiggas- oder Hybridantriebe [167]. Mit dem Symbol AD3 wird der automatisierte Fahrmodus dargestellt, wobei das Fahrzeug ohne manuellen Eingriff des Fahrers sicher am Straßenverkehr teilnimmt.









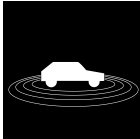


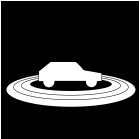
Ein Vorfahrt gewähren für einen Fußgänger wird mit dem aus der Voruntersuchung bekannten Symbol C3 dargestellt. Alternativ wird eine Abwandlung des Zeichens mit einem ergänzten Zebrastreifen (C2) getestet, wodurch eine noch genauere Situationsdarstellung erfolgt. Die Symbole C2 und C3 sind bereits vom Verkehrsschild „Fußgängerüberweg“ und von Fußgängerampeln bekannt [92][153]. Das Symbol C1 zeigt mit zwei entgegengesetzten Pfeilen

etwas abstrakter, dass Fußgänger von beiden Seiten die Straße überqueren dürfen und ähnelt den Symbolen 10 und 21 aus der Voruntersuchung (siehe Abbildung 4.1).

Die Darstellung zur Erkennung von Fußgängern erfolgt über dynamische Symbole und besteht aus vier sequenziellen Bildern (siehe Tabelle 4.2), um mehr Aufmerksamkeit zu erwecken (vgl. Budanow et al. [29]) sowie die fortlaufende Detektion neuer Fußgänger zu visualisieren. Symbol D1 ist das in der Voruntersuchung ausgewählte Zeichen 20. Symbole D2 und D3 stellen drei größer werdende Ringe jeweils unter einem Fahrzeug dar, welche das Ausenden von Wellen und die zugrundeliegende Fahrzeugsensorik visualisieren sollen. Die Darstellung ist bspw. der Ultraschallsensorik eines Parkassistenten nachempfunden [168].

**Tabelle 4.2.:**

Sequentielle Darstellung der dynamischen Symbole für das Erkennen eines Fußgängers, nach [163]

Symbol	Sequenz 1	Sequenz 2	Sequenz 3	Sequenz 4
D1				
D2				
D3				

## Farbauswahl

Farben sind im täglichen Leben omnipräsent und werden mit bestimmten Bedeutungen assoziiert [102]. Deshalb werden für diese Untersuchung sechs verschiedene Farben ausgewählt, welche die Verständlichkeit der oben bestimmten Symbole verstärken sollen. Weiß soll als Bewertungsgrundlage verwendet werden, weil sie nach der Norm ISO 2575 eine Standardfarbe für Zeichen darstellt [27] und da bereits in der Voruntersuchung weiße Zeichen eingesetzt wurden. Weiß wird außerdem in vielen weiteren Studien zur Kommunikation automatisierter Fahrzeuge eingesetzt, z.B. von Othersen et al. und Clamann et al. [19][153]. Zuletzt wird Weiß bereits im heutigen Straßenverkehr für Leuchten in der Fahrzeugfront eingesetzt, z.B. Tagfahrlichter oder Positionsluchten [33]. Die Primärfarbe Grün findet bereits im Straßenverkehr für Ampelanlagen Verwendung und zeigt nach der Norm ISO 2575 einen normalen, sicheren Betriebszustand an [27]. Außerdem wird diese Farbe in verschiedenen Studien zur Fahrzeug-Fußgänger-Kommunikation eingesetzt und in der Arbeit von Willrodt et al. für das Erkennen eines Fahrradfahrers und Vorfahrt gewähren durch das Fahrzeug am besten bewertet [28][169]. Als weitere Farbe für die Kommunikation automatisierter Fahrzeuge wird Blau untersucht, da es mit ca. 80° eine sehr hohe periphere Sichtbarkeit besitzt und damit für die Kommunikation im Straßenverkehr besonders geeignet ist [102]. Auch in der Untersuchung von Willrodt et al. wird Blau ähnlich gut bewertet wie Weiß [169]. Deshalb sollen neben Weiß die Primärfarben Grün und Blau untersucht werden. Auf Rot wird ausdrücklich verzichtet, da diese Farbe in der Fahrzeugbeleuchtung aktuell ausschließlich als Schlusslicht eingesetzt wird. Außerdem wird Rot zur Unterstützung von Warn- und Verbotssymbolen verwendet, z.B. wenn Personen oder Betriebsmittel unmittelbar gefährdet sind [27][102]. Weil keines der untersuchten Symbole eine Warnung oder ein Verbot darstellt und der Warncharakter bestehender Warn- und Verbotssymbole nicht beeinträchtigt werden soll, wird auch aus diesen Gründen auf die Verwendung von Rot ausdrücklich verzichtet.

In der Onlinestudie werden zusätzlich die Sekundärfarben Türkis (Blau-Grün oder Cyan), Gelb und Magenta evaluiert. Besonders Türkis und Magenta sind von im Straßenverkehr verwendeten Farben gut zu unterscheiden [102].

Deshalb empfiehlt auch der SAE Standard J3134 die Verwendung blau-grüner Leuchten, um anzuzeigen, dass sich ein Fahrzeug im automatisierten Fahrmodus befindet [31]. Magenta wird in einer Untersuchung von Beggiato et al. sehr gut im Bezug auf dessen Sichtbarkeit im Straßenverkehr bewertet [170]. Gelbe Zeichen sind in der Norm ISO 2575 für Achtungszeichen vorgesehen [27] und werden auch in anderen Studien zur Fahrzeug-Fußgänger-Kommunikation automatisierter Fahrzeuge eingesetzt [28][171]. Alle Symbole dieser Onlinestudie sind in Abbildung 4.4 in den sechs ausgewählten Farben dargestellt.

### **Untersuchung der Bildschirmfarbwiedergabe**

Vor der Durchführung einer Onlinestudie zur unterstützenden Wirkung von Farben auf die Verständlichkeit von Symbolen soll sichergestellt werden, dass die Darstellung der Farben für unterschiedliche Bildschirme gleich oder zumindest sehr ähnlich erfolgt. Dies ist notwendig, um die Wahrnehmung unterschiedlicher Farben bei konstanten Farbwerten zu verhindern. Dazu werden 21 Bildschirme mit Hilfe eines Kolorimeters (UPRtek MK350S) bzgl. deren Farbwiedergabe vermessen. Für die Messung wird an den Displays jeweils eine Primärfarbe (Rot, Grün, Blau) sowie Weiß nacheinander dargestellt und damit deren xy-Koordinaten bestimmt [26]. Die Messgenauigkeit des hierfür verwendeten Kolorimeters kann mit der angegebenen Toleranz von  $\pm 0,0025$  vernachlässigt werden. Die Sekundärfarben (Cyan, Magenta, Gelb) werden aus den gemessenen Primärfarben und Weiß berechnet. Die so bestimmten Farbwerte, deren Standardabweichung sowie der daraus resultierende Gamut sind in Abbildung 4.5 in gelb dargestellt, der sRGB-Farbraum in schwarz. Der Gamut umfasst dabei alle von einem Wiedergabegerät darstellbaren Farben [26].

In Abbildung 4.5 sind außerdem die ungefähr zu unterscheidenden Farbnamen nach Fortner und Meyer dargestellt [173]. Aus der Messung der Primärfarben und Weiß, ergeben sich die Farbnamen nach Fortner und Meyer zu Weiß, Rötlich-Orange, Gelblich-Grün und Lilafarbenes-Blau. Weiß, Gelblich-Grün und Lilafarbenes-Blau liegen mit ihrer Standardabweichung ausschließlich in einem Farbbereich, während das Rötlich-Orange auch als Rot wahrgenommen werden kann. Die berechneten Sekundärfarben sind Blau-Grün, Gelb-Grün





### 4.3.2. AUFBAU DER ONLINESTUDIE

Die Onlinestudie wird auf zwei Plattformen, Amazon Mechanical Turk (MTurk) und Prolific, nordamerikanischen und westeuropäischen Probandenpools zur Verfügung gestellt [174][175]. Um eine möglichst breite Stichprobe zu erzielen, sollen jeweils 400 Probanden akquiriert werden, wobei die registrierten Benutzer von MTurk und Prolific regionale Schwerpunkte bilden. Die Onlinestudie wird für eine durchschnittliche Bearbeitungsdauer von 25 bis 30 Minuten entwickelt und ist in englischer Sprache gestaltet. Nach einer vollständigen und erfolgreichen Studienteilnahme werden die Probanden plattformspezifisch finanziell leicht überdurchschnittlich kompensiert, um die Attraktivität der Studie zu erhöhen und dadurch möglichst schnell die gewünschte Teilnehmerzahl zu erreichen. Zur Sicherstellung qualitativ hochwertiger Antworten ermöglicht MTurk eine Vorauswahl der Probanden über eine filternde Teilnehmerzulassung. Angelehnt an Fridman et al. wird vorausgesetzt, dass die Probanden mindestens 1000 erfolgreich durchgeführte MTurk-Aufgaben (Human Intelligent Tasks) und eine zu 95% positive Bewertung (Review-Rate) aufweisen [28]. Bei Prolific besteht die für MTurk beschriebene Möglichkeit nicht, Filter für die Teilnehmer zu setzen. Eine hohe Güte der Antworten muss anschließend durch ein manuelles Bewerten der ausgefüllten Fragebögen sichergestellt werden.

Die Onlinestudie besteht aus einer Mischung von Tests zur Aussagekraft, nach McDougall et al. [155], und Verständlichkeit, nach Collins und Lerner [156]. Die Struktur der fünf Hauptteile bleibt für jeden Teilnehmer gleich, jedoch wird die Symbol- und Farbreihenfolge für jeden Probanden zufällig generiert, um Lern- und Initialisierungseffekte auszuschließen [160].


Als Einführung wird den Probanden im ersten Teil der Ablauf und die Dauer der Onlinestudie mitgeteilt. Nach Akzeptieren der Teilnahmebedingungen und nach Zusage der Probanden, die Onlinestudie an einem Desktop-PC durchzuführen, wird das Farbsehen der Probanden getestet. Da die Studienteilnehmer im vierten Teil der Studie verschiedenfarbige Symbole erkennen und bewerten müssen, wird eine Rot-Grün-Schwäche (Deuteranopie bzw. Protanopie) mittels der Ishihara-Farbtafel 8 (Zahl „15“) ausgeschlossen [176]. Diese ist die häufigste Farbfehlsichtigkeit in einer europäischen Bevölkerung

[102][177]. Der Test des Farbsehens nach Ishihara kann nach Hoffmann und Menozzi sowohl in ausgedruckter Form, als auch mit Hilfe von Computerdisplays erfolgen [178].

Um die Aufmerksamkeit der Probanden auf den Bereich zu lenken, welcher im weiteren Verlauf der Onlinestudie für die Anzeige der Symbole genutzt wird (vgl. Abbildung 4.7), wird ihnen dieser in einem Beispiel mit großen Smileys am Fahrzeug verdeutlicht. Dieses Vorgehen wird von Fridman et al. für Onlinestudien empfohlen [28]. Die Darstellung der Smileys wird darüber hinaus für zwei Filterfragen eingesetzt, bei welchen die Probanden einerseits bestätigen, dass sie das Symbol im Bild finden können und andererseits überprüft wird, ob die Teilnehmer die Anweisungen in der Studie genau lesen. Ein falsches Auswählen der Antworten führt zum Ausschluss aus der Datenerhebung, wodurch die Qualität der Studienergebnisse gesteigert wird.

Allen verbliebenen Probanden wird die in der Onlinestudie zugrunde gelegte Verkehrssituation anhand einer Abbildung erläutert (siehe Abbildung 4.6). Die Studienteilnehmer sollen sich dabei in die Situation eines Fußgängers versetzen, der eine zweispurige Straße an einem Fußgängerüberweg überqueren möchte. Gleichzeitig nähert sich ein Fahrzeug und ein Kreuzen der Fahrzeug- und Fußgängertrajektorie ist zu erwarten. Eine Straßenführung mit zwei Fahrbahnen je Richtung, wie sie in Abbildung 4.6 und Abbildung 4.7 dargestellt ist, kann v.a. in den USA, aber auch in Europa angetroffen werden. Beide Abbildungen zeigen damit eine für das ausgewählte Probandenkollektiv gewohnte Situation im Straßenverkehr.

Im zweiten Teil der Onlinestudie werden weiße Symbole gezeigt, welche die Probanden bezüglich deren Aussagekraft und Verständlichkeit bewerten. Dabei handelt es sich um eine möglichst realistische Darstellung einer Verkehrssituation, in welche ein Audi Aicon eingebettet ist (siehe Abbildung 4.7). In der gesamten Studie wird diese bearbeitete Verkehrssituation verwendet, um die Symbole und Farben darzustellen. Die Probanden haben keinerlei Vorwissen zur Bedeutung der Zeichen. Sie sollen ähnlich zur Voruntersuchung die Aussagekraft auf einer sechsstufigen Likert-Skala bewerten und eine kurze offene Antwort zur Bedeutung des Symbols eingeben (max. 100 Zeichen). Die Aussagekraft wird von „1: ich verstehe die Bedeutung überhaupt nicht“ bis „6: ich verstehe die Bedeutung voll und ganz“ angegeben. Zusätzlich werden die



**Abbildung 4.6.:** Situationsbeschreibung des Versuchsaufbaus, nach [165]

Probanden aufgefordert, zu bewerten, wie sicher sie sich mit ihrer offenen Antwort sind. Auch bei dieser Bewertung der Konfidenz wird die Auswahl über eine sechsstufige Likert-Skala von „1: ich liege sicher falsch“ bis „6: ich liege sicher richtig“ getroffen. Mit der Frage wie sicher sich die Probanden bei ihrer Aussage sind, kann in der Auswertung ein Raten der richtigen Bedeutung ausgeschlossen werden [156].

Der dritte Teil der Onlinestudie ist ähnlich dem zweiten Teil und an die Voruntersuchung angelehnt. Auch in diesem Abschnitt werden den Probanden die Symbole in zufälliger Reihenfolge und anhand des bearbeiteten Bilds des Audi Aicons gezeigt. Sie werden aufgefordert, dem Symbol eine aus drei vorgegebenen Bedeutungen zuzuordnen und anschließend auszuwählen, wie sicher sie sich mit ihrer Auswahl sind. Diese Bewertung der Sicherheit durch die Probanden erfolgt wieder anhand einer sechsstufigen Skala. Die vorgegebenen Antworten wurden für jedes Symbol vor der Studie durch drei Studienleiter ausgewählt, um möglichst sinnvolle Falschantworten zu generieren.

Im vierten Hauptteil wird den Studienteilnehmern nach einem Beispielbild jeweils ein Symbol in allen Farben gezeigt, welches sie in Bezug auf eine vorgegebene Bedeutung bewerten müssen. Die Bedeutungen entsprechen den




**Abbildung 4.7.:** Audi Aicon mit angezeigtem Symbol C2 [105]

angestrebten Darstellungen für einen automatisierten Fahrmodus, Vorfahrt gewähren und Erkennen eines Fußgängers. Die Probanden ordnen auch hier mit Hilfe einer sechsstufigen Likert-Skala ihre Konfidenz ein, und geben damit an, wie sicher sie sich sind, dass die Bedeutung auf das gezeigte Symbol zutrifft („1: ich bin überhaupt nicht sicher“ bis „6: ich bin sehr sicher“).

Im fünften und letzten Teil der Studie werden demographische Daten der Probanden erfasst. Diese beinhalten das Alter, Geschlecht und Herkunft. Außerdem wird neben dem Englischniveau („War das Englischniveau für Ihre Sprachkenntnisse angemessen?“) und der Lieblingsfarbe der Studienteilnehmer nach der jeweils geeignetsten Farbe für die drei untersuchten Nachrichten gefragt. Zuletzt wird abgefragt, wie vertraut die Probanden mit ähnlichen Situationen im Straßenverkehr sind.

### 4.3.3. AUSWERTUNG UND DISKUSSION DER ONLINESTUDIE

Nach Anwenden der Filterfragen aus dem ersten Teil der Studie und einer manuellen Überprüfung durch drei Personen verbleiben 709 Probanden im Datensatz. Das händische Überprüfen ist vor allem wegen den fehlenden Filtermöglichkeiten bei Prolific notwendig. Die Aufteilung zwischen den Plattformen MTurk (48,2%) und Prolific (51,8%) ist nahezu identisch. Die Studienteilnehmer kommen zu großen Teilen aus den USA (46,7%) und dem vereinigten Königreich (51,6%), nur vereinzelte Personen sind aus Kanada oder europäischen Staaten. 61,6% der Probanden sind weiblich, 37,8% männlich und zwei Testpersonen wollen ihr Geschlecht nicht nennen oder können es keiner der Kategorien zuordnen. Der Großteil der Teilnehmer ist mit der gezeigten Verkehrssituation sehr vertraut und lebt in einer Stadt (30,5%) oder Vorstadt (49,5%) und hat selbst eine Fahrerlaubnis für Kraftfahrzeuge (84,5%). Die Altersverteilung in Abbildung 4.8 zeigt, dass trotz einer großen Bandbreite hauptsächlich Probanden im Alter zwischen 20 und 30 (32,4%) bzw. 31 bis 40 (30,3%) Jahren an der Onlinestudie teilnehmen.



**Abbildung 4.8.:** Altersverteilung der Probanden in der Onlinestudie, nach [163]

### **Aussagekraft und Verständlichkeit der Symbole**










Die Bewertung der Aussagekraft und Verständlichkeit der Symbole erfolgt mittels verschiedener statistischer Methoden. So wird der t-Test angewendet um festzustellen, ob ein Mittelwert signifikant unterschiedlich zu einem zweiten (Mittel-)Wert ist oder dieser lediglich zufallsbedingt höher bzw. niedriger ausfällt. Mit Hilfe eines z-Tests kann mit einer bestimmten statistischen Sicherheit gesagt werden, ob ein definierter Erwartungswert eingehalten wird oder nicht [160]. Die Auswertung der Antworten für den erstmaligen Symbolkontakt erfolgt mittels eines einseitigen t-Tests für die Aussagekraft und Sicherheit der Antworten sowie mittels eines z-Tests für die Erkennungsraten der offenen Antworten. Für die Auswertungen werden ein Signifikanzniveau von  $\alpha \leq 0,05$ , ein kritischer Wert von 1,64 und ein Konfidenzintervall von 90 % angesetzt. Die Zahl der Freiheitsgrade beträgt für alle Untersuchungen 708, also eins weniger als die Anzahl der Probanden [160]. Für die Auswertung der Aussagekraft wird für jedes Symbol ein einseitiger t-Test gegen den Mittelwert der sechsstufigen Skala (3,5) berechnet (siehe Kapitel 4.1). Die Ergebnisse in Tabelle 4.3 zeigen eine sehr hohe Signifikanz für die Aussagekraft der Symbole C2 ( $t(708) = 21,05; p < 0,05$ ) und C3 ( $t(708) = 11,05; p < 0,05$ ). Die Pearson-Korrelationskoeffizienten  $r$  weisen nach Cohen für das Symbol C3 einen mittleren und für C2 einen starken Effekt auf [179].

Die offenen Antworten für die Bedeutung der Symbole aus dem zweiten Teil der Onlinestudie werden in die vier Kategorien „richtig“, „teilweise richtig“, „falsch“ und „keine Antwort“ unterteilt. Antworten werden als „richtig“ gewertet, wenn sie zeigen, dass die Probanden die Bedeutung der Symbole verstanden haben. Hierbei werden Abkürzungen, Synonyme und andere Beschreibungen akzeptiert. „Teilweise richtig“ sind Antworten die erkennen lassen, dass die Bedeutung der Symbole verstanden wird, aber zu generell, speziell oder wörtlich beschrieben sind. Antworten mit vollständig falscher Bedeutung werden als „falsch“ gewertet. Diese Kodierung erfolgt durch drei Prüfer unabhängig voneinander und wird über ein Mehrheitsvotum festgelegt.

Für die Berechnung der Erkennungsraten der Symbole werden alle „richtig“ und „teilweise richtig“ klassifizierten Antworten als korrekt und die Kodierungen aller Kategorien für die Gesamtzahl der Antworten eingesetzt. Die

**Tabelle 4.3.:**

Ergebnisse des einseitigen t-Tests für die Auswertung der Aussagekraft der Symbole, nach [163]

	Symbol	Mittelwert	Standardabw.	t	r
	AD1	1,77	1,18	-39,15	-
	AD2	1,83	1,22	-36,31	-
	AD3	3,28	1,43	-4,14	-
	C1	2,60	1,47	-16,24	-
	<b>C2</b>	4,55	1,33	21,06***	0,62
	<b>C3</b>	4,10	1,45	11,05***	0,38
	D1	3,11	1,48	-7,02	-
	D2	2,64	1,40	-16,40	-
	D3	2,59	1,44	-16,93	-

Für nicht signifikant aussagekräftige Symbole kann kein  $r$  berechnet werden. Dies wird mit '-' vermerkt. \*\*\* zeigt, dass ein  $p$ -Wert von  $p < 0,001$  erreicht wird.

Erkennungsraten (ER) werden mit einem z-Test gegen die minimale Erkennungsrate von 67 % getestet (siehe Kapitel 4.1). Wie in Tabelle 4.4 dargestellt, sind ausschließlich die Erkennungsraten für die offenen Antworten der Symbole C2 ( $z = 15,97; p < 0,05$ ) und C3 ( $z = 11,82; p < 0,05$ ) signifikant aussagekräftig.










Häufige Falschantworten enthalten Beschreibungen der Symbole oder der zugrundeliegenden Situation, z.B. „Fußgänger“, „Überqueren“ oder „Fahrzeug“. Außerdem wird bspw. das „Audi-AI“ Logo mit einem Warnzeichen und Symbole D2 und D3 mit Sensoren verwechselt. Symbol AD3 wird in vielen Fällen als Anhalten oder Abbiegen gedeutet.

Die Probanden geben im gleichen Zusammenhang an, wie sicher sie sich sind, dass ihre offenen Antworten richtig sind. Diese Bewertung wird wie die Aussagekraft durch einen einseitigen t-Test mit dem Mittelwert der Skala (3,5) verglichen (siehe Kapitel 4.1). Ähnlich wie in den anderen beiden Tests zeigt Tabelle 4.5, dass die mittleren Sicherheiten ausschließlich für die Antworten zu



**Tabelle 4.4.:**

Ergebnisse des z-Tests für die Auswertung der Erkennungsraten der Symbole (offene Antworten), nach [163]

	Symbol	ER [%]	z
	AD1	14,95	-29,55
	AD2	21,44	-25,88
	AD3	55,29	-6,65
	C1	36,67	-17,23
	<b>C2</b>	95,20	15,97
	<b>C3</b>	87,87	11,82
	D1	51,76	-8,63
	D2	30,89	-20,45
	D3	29,48	-22,25










den Symbolen C2 ( $t(708) = 19,71; p < 0,05$ ) und C3 ( $t(708) = 8,61; p < 0,05$ ) signifikant höher sind als der von Tijus et al. definierte Schwellwert (vgl. Tabelle 4.3 und Tabelle 4.4) [21]. Auch in diesem Fall weisen die Pearson-Korrelationskoeffizienten  $r$  für das Symbol C3 einen mittleren und für C2 einen starken Effekt auf [179].

Die Ergebnisse zeigen, dass die Symbole C2 und C3 intuitiv verständlich und aussagekräftig sind sowie mit einer hohen angegebenen Sicherheit von 4,43 und 3,95 erkannt werden. Besonders das Symbol C2 wird stets sehr gut bewertet. Der einzige Unterschied zu Symbol C3 besteht in dem stilisiert dargestellten Zebrastreifen. Alle anderen Symbole sind in der offenen Abfrage nicht ausreichend aussagekräftig und weisen niedrige Erkennungsraten auf. Dies bestätigt, dass v.a. bereits aus dem Straßenverkehr bekannte Symbole richtig erkannt werden, unbekannt jedoch nur eine geringe Aussagekraft bzw. Intuitivität besitzen.

Auch für die vorgegebenen Antworten aus dem dritten Teil der Onlinestudie werden die berechneten Erkennungsraten mit dem Schwellwert von 67% verglichen (siehe Kapitel 4.1). Dabei sind die Erkennungsraten der Symbole AD3 ( $z = 8,32; p < 0,05$ ), C2 ( $z = 9,51; p < 0,05$ ) und D1 ( $z = 11,83; p < 0,05$ )

**Tabelle 4.5.:**










Ergebnisse des einseitigen t-Tests für die Auswertung der Sicherheit/Konfidenz der offenen Antworten, nach [163]

	Symbol	Mittelwert	Standardabw.	t	r
	AD1	2,08	1,37	-27,66	-
	AD2	2,06	1,35	-28,43	-
	AD3	3,28	1,39	-4,30	-
	C1	2,68	1,45	-15,08	-
	<b>C2</b>	4,43	1,26	19,71***	0,59
	<b>C3</b>	3,95	1,39	8,61***	0,31
	D1	3,14	1,46	-6,60	-
	D2	2,74	1,43	-14,15	-
	D3	2,64	1,41	-16,35	-

Für nicht signifikant sichere Antworten kann kein  $r$  berechnet werden. Dies wird mit '-' vermerkt. \*\*\* zeigt, dass ein  $p$ -Wert von  $p < 0,001$  erreicht wird.

**Tabelle 4.6.:**

Ergebnisse des z-Tests für die Auswertung der Erkennungsraten der Symbole (vorgegebene Antworten), nach [163]

	Symbol	ER [%]	z
	AD1	23,70	-24,52
	AD2	48,66	-10,36
	<b>AD3</b>	81,66	8,32
	C1	54,30	-7,19
	<b>C2</b>	83,78	9,51
	C3	58,53	-4,81
	<b>D1</b>	87,87	11,83
	D2	37,38	-16,76
	D3	36,39	-17,33

signifikant höher als der definierte Schwellwert (siehe Tabelle 4.6). Für das










Symbol C3 wählen nur 58,53 % der Probanden die korrekte Antwort, während 39,35 % das Symbol fälschlicherweise als „Das Fahrzeug hat einen Fußgänger erkannt“ deuten. Dies kann daran liegen, dass die richtige Bedeutung des Vorfahrt-gewährens voraussetzt, dass ein Fußgänger erkannt wird oder, dass die Probanden im Teil drei der Studie bereits alle Symbole sahen und deshalb auf eine andere Bedeutung des Zeichens schlussfolgern.

Die Probanden bewerten ihre Auswahl der vorgegebenen Antworten für fünf Symbole signifikant sicherer als den Mittelwert der Skala 3,5 (siehe Tabelle 4.7). Das Symbol C1 ( $t(708) = 2,35; p < 0,05$ ) zeigt dabei einen kleinen Effekt ( $r < 0,1$ ), während Symbole AD3 ( $t(708) = 19,60; p < 0,05$ ), C2 ( $t(708) = 33,24; p < 0,05$ ), C3 ( $t(708) = 18,60; p < 0,05$ ) und D1 ( $t(708) = 16,71; p < 0,05$ ) jeweils einen starken Effekt ( $r > 0,5$ ) aufweisen. Dies zeigt deutlich, dass Probanden die verständlichen Symbole AD3, C2 und D1 nicht nur richtig deuten können, sondern dass sie sich bei ihrer Auswahl auch sehr sicher sind. Dadurch kann ein Erraten der richtigen Antworten ausgeschlossen werden. Hervorzuheben ist jedoch, dass sich die Probanden bei ihrer Auswahl zu den Symbole C1 und C3 sehr sicher sind, obwohl die dazugehörigen Erkennungsraten das geforderte Kriterium aus Kapitel 4.1 nicht erfüllen. Dies weist darauf hin, dass ein großer Teil der Probanden eine falsche Antwortoption als richtig deutet und damit die Zeichen mehrdeutig sind.

Die Symbole AD3 (automatisierter Fahrmodus), C2 (Vorfahrt gewähren für Fußgänger) und D1 (Erkennen eines Fußgängers) zeigen für die jeweiligen Nachrichten die besten Ergebnisse aus den untersuchten Zeichen (siehe Abbildung 4.9). Symbol C2 kann mit hoher Intuitivität auch bei offenen Fragen erkannt werden, während Probanden AD3 und D1 lediglich aus vorgegebenen Antworten sehr sicher der richtigen Bedeutung zuordnen können. Die Ergebnisse bestätigen die Voruntersuchung zur Intuitivität von Zeichen und Dynamiken (siehe Kapitel 4.2) und zeigen, dass lediglich bekannte Symbole intuitiv verständlich und aussagekräftig sind. Unbekannte Symbole oder Nachrichten, die heute im Straßenverkehr nicht notwendig sind, besitzen eine geringe Intuitivität (z.B. automatisierter Fahrmodus). Im Gegensatz dazu werden manche Symbole mit hohen Erkennungsraten erkannt, wenn verschie-

**Tabelle 4.7.:**

Ergebnisse des einseitigen t-Tests für die Auswertung der Sicherheit/Konfidenz der vorgegebenen Antworten, nach [163]

	Symbol	Mittelwert	Standardabw.	t	r
	AD1	3,29	1,27	-4,34	-
	AD2	3,21	1,33	-5,82	-
	<b>AD3</b>	4,44	1,28	19,60***	0,99
	<b>C1</b>	3,62	1,34	2,35*	0,08
	<b>C2</b>	4,83	1,07	33,24***	0,78
	<b>C3</b>	4,31	1,15	18,60***	0,57
	<b>D1</b>	4,31	1,30	16,71***	0,53
	D2	3,31	1,24	-4,05	-
	D3	3,31	1,24	-4,08	-

Für nicht signifikant sichere Antworten kann kein  $r$  berechnet werden. Dies wird mit '-' vermerkt. \* zeigt, dass ein p-Wert von  $p < 0,05$  erreicht wird, \*\*\* weist auf einen p-Wert von  $p < 0,001$  hin.

dene Antwortmöglichkeiten zur Auswahl stehen. Dies deutet darauf hin, dass Symbole mit bereits gelerntem Vorwissen sicher erkannt werden können.



**Abbildung 4.9.:** Ausgewählte Symbole der Onlinestudie für eine verständliche Fahrzeug-Fußgänger-Kommunikation, nach [163]

### **Einfluss von Farben auf die Verständlichkeit von Symbolen**




Die Sicherheit der Probanden, dass ein farbiges Symbol eine bestimmte Nachricht visualisieren soll, wird mit Hilfe einer Varianzanalyse (Analysis of Variance (ANOVA)) ausgewertet. Eine Voraussetzung hierfür ist das Kriterium

der Sphärizität. Diese Voraussetzung kann mit einem Mauchly-Test überprüft werden und wird im vorliegenden Fall verletzt. Deshalb muss die Sphärizität durch eine Greenhouse-Geisser- bzw. Huynh-Feldt-Korrektur hergestellt werden. Die korrigierte ANOVA mit Messwiederholung zeigt dabei für jedes Symbol einen signifikanten Unterschied zwischen den Konfidenzbewertungen der Farben (siehe Tabelle A.1, Anhang A.2). Diese Varianzen werden anschließend mit einem Post-Hoc-Test bzgl. des kleinsten signifikanten Unterschieds genauer untersucht. Nähere Ausführungen dieser statistischen Methoden werden durch Field beschrieben [160].

In Tabelle 4.8 sind die mittleren Konfidenzbewertungen für die Symbole AD1, AD2 und AD3 aufgeführt. Sie zeigen, wie sicher sich die Probanden sind, dass das Zeichen in der jeweiligen Farbe einen automatisierten Fahrmodus darstellt. Die beste Zuordnung der farbigen Symbole zur vorgegebenen Nachricht erfolgt jeweils für die Farben Grün ( $\bar{x} = 3,69$ ) und Weiß ( $\bar{x} = 3,60$ ). Die niedrigste Sicherheit zeigen die Farben Blau ( $\bar{x} = 3,06$ ) und Magenta ( $\bar{x} = 3,01$ ). Diese Rangfolge gilt für alle Symbole dieser Nachricht, wobei jeweils kein signifikanter Unterschied ( $p > 0,05$ ) zwischen den Farben Blau und Magenta besteht. Darüber hinaus kann für das Symbol AD3 kein signifikanter Unterschied ( $p > 0,05$ ) zwischen den Farben Weiß und Grün nachgewiesen werden.

**Tabelle 4.8.:**

Mittlere Konfidenzbewertung der untersuchten Symbole für die Darstellung eines automatisierten Fahrmodus, nach [163]

	Symbol	Weiß	Grün	Türkis	Blau	Gelb	Magenta
	AD1	2,93	3,01	2,67	2,52	2,84	2,48
	AD2	3,41	3,58	3,13	2,96	3,25	2,91
	AD3	4,46	4,48	4,01	3,70	4,11	3,64
	$\bar{x}$	3,60	3,69	3,27	3,06	3,50	3,01

Die Auswertung der farbigen Symbole C1, C2 und C3 für die Nachricht des Vorfahrt-gewährens erfolgt wie für den automatisierten Fahrmodus. Tabelle 4.9 zeigt, dass die mittlere Konfidenzbewertung für die Farbe Grün stets am

höchsten ist ( $\varnothing = 4,87$ ). Die durchschnittliche Sicherheit der Probanden für weiße Symbole kann mit 4,22 angegeben werden. Blau ( $\varnothing = 3,33$ ) und Magenta ( $\varnothing = 3,18$ ) werden wieder am schlechtesten bewertet. Für die Symbole C1 und C3 besteht zwischen Blau und Gelb kein signifikanter Unterschied ( $p > 0,05$ ).

**Tabelle 4.9.:**

Mittlere Konfidenzbewertung der untersuchten Symbole für Vorfahrt gewähren für Fußgänger, nach [163]


	Symbol	Weiß	Grün	Türkis	Blau	Gelb	Magenta
	C1	3,52	4,22	3,17	2,91	2,98	2,74
	C2	4,78	5,33	4,20	3,68	3,86	3,57
	C3	4,37	5,06	3,84	3,40	3,50	3,23
	$\varnothing$	4,22	4,87	3,74	3,33	3,45	3,18

Tabelle 4.10 zeigt die Konfidenzbewertung der farbigen Symbole D1, D2 und D3 für das Erkennen eines Fußgängers. Wie bereits bei den anderen beiden Nachrichten bewerten Probanden die Farben Weiß ( $\varnothing = 3,82$ ) und Grün ( $\varnothing = 3,89$ ) stets mit hoher Sicherheit, dass das Zeichen die vorgegebenen Bedeutung darstellt. Für das Symbol D1 besteht zwischen diesen beiden Farben kein signifikanter Unterschied ( $p > 0,05$ ). Die Symbole D2 und D3 weisen für Grün die höchsten Konfidenzbewertungen auf. Die am niedrigsten bewerteten Farben sind jeweils Blau ( $\varnothing = 3,16$ ) und Magenta ( $\varnothing = 3,17$ ). Diese Farben zeigen wieder für keines der Zeichen für das Erkennen eines Fußgängers einen signifikanten Unterschied ( $p > 0,05$ ). Auch die Bewertungen der Farben Türkis und Gelb unterscheiden sich im Symbol D1 nicht signifikant ( $p > 0,05$ ).

Die mittleren Konfidenzbewertungen der Probanden für die untersuchten Farben sind in Abbildung 4.10 zusammengefasst dargestellt. Die höchsten Bewertungen erhalten die farbigen Zeichen für die Botschaft Vorfahrt gewähren, während die niedrigsten für die Visualisierung des automatisierten Fahrzustands gemessen werden können. Die Rangfolge der Farben ist für den automatisierten Fahrmodus und das Erkennen eines Fußgängers gleich


**Tabelle 4.10.:**

Mittlere Konfidenzbewertung der untersuchten Symbole für das Erkennen eines Fußgängers, nach [163]

	Symbol	Weiß	Grün	Türkis	Blau	Gelb	Magenta
	D1	4,68	4,63	4,06	3,68	4,10	3,72
	D2	3,43	3,56	3,14	2,92	3,24	2,91
	D3	3,34	3,48	3,11	2,88	3,24	2,88
	∅	3,82	3,89	3,44	3,16	3,53	3,17

und zeigt, dass Weiß und Grün mit nur kleinen Unterschieden die besten Bewertungen erhalten. Blau und Magenta sind für diese beiden Nachrichten jeweils die am niedrigsten bewerteten Farben, wobei sich deren Konfidenzbewertungen für die Nachrichten „Fußgänger darf gehen“ und „Fahrzeug hat Fußgänger erkannt“ nicht signifikant unterscheiden. Dieses Ergebnis kann mit dem geringeren Kontrast der Farben zum dunklen Hintergrund des Audi Aicon in Verbindung stehen. Die gelb dargestellten Zeichen werden für den automatisierten Fahrmodus und das Erkennen eines Fußgängers tendenziell besser bewertet als die türkisen Symbole. Dass alle Farben mit Blauanteilen schlechter bewertet werden als diejenigen ohne, kann darauf hinweisen, dass bläuliche Farben für diese beiden Nachrichten nur bedingt geeignet sind. Für das Gewähren der Vorfahrt von Fußgängern wird Grün signifikant besser als Weiß bewertet. Für diese Nachricht ist Türkis die Farbe mit dritthöchster Konfidenzbewertung. Dies kann mit der Ähnlichkeit von Blau-Grün mit Grün bzw. Gelblich-Grün und der Verwendung von Grün als Signalfarbe im Straßenverkehr begründet werden. Grün wird bei Ampelanlagen eingesetzt, um das Erteilen einer Vorfahrt anzuzeigen.

Diese Ergebnisse bekräftigen Ergebnisse von Willrodt et al. [169]. Auch hier ist Grün die am signifikant höchsten bewertete Farbe für das Erkennen eines Fußgängers und für Vorfahrt gewähren. In der hier vorgestellten Untersuchung erzielen Grün und Weiß ähnliche Ergebnisse und unterscheiden sich für die Symbole AD3 und D1 nicht signifikant in ihren Konfidenzbewertungen, mit der Ausnahme des Vorfahrt-gewährens. Ein Vorfahrt gewähren verbinden die Probanden mit der gleichen Bedeutung der bereits im Straßenverkehr



**Abbildung 4.10.:** Mittlere Konfidenzbewertung der Farben für die drei untersuchten Nachrichten [105]

erlernten Farbe Grün. Dies legt nahe, dass auch Farben nicht intuitiv einer bestimmten Nachricht zugeordnet werden können und sie vielmehr gelernt werden müssen. Diese Erkenntnis trifft auch auf die von der Gesetzgebung vorgeschlagene Farbe Türkis für die Kommunikation und Signalisierung automatisierter Fahrzeuge zu (siehe Anhang 2.1.2). Möglicherweise unterstützt eine im Straßenverkehr unübliche Farbe den Lernprozess für die richtige Zuordnung von Symbolen und Bedeutungen, wobei dann v.a. Türkis und Magenta relevant wären.

Die Auswertung der Onlinestudie legt die Verwendung grüner Symbole, v.a. zur Darstellung des Vorfahrt-gewährens für Fußgänger, nahe. Einschränkend muss jedoch auf die potentielle Verwechslungsgefahr mit bestehenden Ampelanlagen und Zeichen im Straßenverkehr hingewiesen werden. Eine Nachricht, die fälschlicherweise als Vorfahrt gewähren interpretiert wird, kann zu schwerwiegenden Unfällen führen. Außerdem kann Grün nicht von allen farbfehlsichtigen Verkehrsteilnehmern wahrgenommen werden, wodurch die



unterstützende Wirkung auf die Verständlichkeit der Symbole entfällt. Dies wurde in [105] mit einer Stichprobe von acht Probanden nachgewiesen und gilt besonders auch für die Farbe Türkis bzw. Blau-Grün, was durch deren wahrgenommene Ähnlichkeit zu Grün bedingt ist.

Diese Evaluation der Onlinestudie und auch die Ergebnisse der in Kapitel 4.2 beschriebenen Voruntersuchung zeigen deutlich, dass Zeichen häufig nicht intuitiv verstanden werden. So werden lediglich die Symbole 27, C2 und C3, welche aus dem Straßenverkehr bekannt sind, intuitiv erkannt. Eine Kombination von Farben und Zeichen erhöht die Intuitivität in den meisten Fällen nicht. Nur für grüne Symbole des Vorfahr-Gewährens erhöht sich die Aussagekraft gegenüber weißen Zeichen signifikant. Dies zeigt eindeutig, dass Symbole und Farben für eine Fahrzeug-Fußgänger-Kommunikation erlernt werden müssen, bevor sie zuverlässig im Straßenverkehr eingesetzt werden können. Eine Möglichkeit hierfür wäre, die Zeichen bereits beim „manuellen Fahren“, parallel zur bekannten Kommunikation des Fahrers, anzuzeigen, damit Fußgänger ein mentales Modell aufbauen und beide Kommunikationsarten in Verbindung bringen können. Ein automatisches, sicheres und komfortables Anzeigen der entsprechenden Symbole ist mit Hilfe einer Fahrerintentionserkennung an Zebrastrifen möglich, welche erkennt, ob ein Fahrer anhalten möchte oder nicht. Nach der Aufstellung einer Untersuchungskritik zu den beiden Studien, wird im darauffolgenden Kapitel 5 ein geeigneter Algorithmus zur Fahrerintentionserkennung vorgestellt.

#### **4.4. UNTERSUCHUNGSKRITIK**

Für die vorgestellte Voruntersuchung und die Onlinestudie können einzelne Kritikpunkte aufgeführt werden. So wurde in keiner der beiden Studien ein bewegtes Fahrzeug in einer Realfahrtstudie oder ein vorhandener Fußgängerüberweg im Straßenverkehr eingesetzt. Dies bedeutet, dass keine reale Situation bewertet wurde. Diese Untersuchungskritik kann teilweise durch eine Arbeit von Othersen et al. zurückgewiesen werden, da die Autoren eine Realfahrtstudie mit der Darstellung weißer Symbole durchführten und zu

ähnlichen Ergebnissen kommen [19]. Die Verständlichkeit der Zeichen könnte durch die Fahrzeugbewegung und einer Abfolge unterschiedlicher Symbole erhöht werden.

Die Ergebnisse geben einen Einblick in die lichtbasierte Fahrzeug-Fußgänger-Kommunikation, wobei v.a. in der Voruntersuchung, aber auch in der Onlinestudie kaum Senioren und keine Kinder in die Stichproben einbezogen wurden. Die Altersverteilungen der hier ausgewählten Stichproben ermöglicht lediglich eine eingeschränkte Deutung der Ergebnisse für eine künftige Kommunikation im Straßenverkehr. Aus der Literatur ist bekannt, dass sich sowohl jüngere, als auch ältere Verkehrsteilnehmer anders verhalten als durchschnittliche Erwachsene. So zeigen bspw. Hsu et al., dass Kinder im Straßenverkehr generell zu wenig aufmerksam sind und Senioren konservativer als durchschnittliche Erwachsene entscheiden, wenn sie eine Straße überqueren [180].

Weiter beeinflusst jede Auswahl auf ein bestimmtes Probandenkollektiv die Ergebnisse einer Untersuchung. In den hier vorgestellten Studien wird diese durch die Wahl der Probandenpools und die verwendeten Filterfragen der Onlinestudie beeinflusst. Die Ergebnisse können deshalb lediglich eine Tendenz für reale Verkehrssituationen mit zufälligen Kommunikationspartnern liefern.

Außerdem untersuchen beide Studien ausschließlich die Kommunikation eines Fahrzeugs mit einem einzelnen Fußgänger. Im Straßenverkehr sind jedoch häufig mindestens zwei Verkehrsteilnehmer gleichzeitig an einer Kommunikation beteiligt und so stellt sich bspw. die Frage, an wen die Nachricht adressiert ist. Dies könnte mittels einer gerichteten Lichtquelle, wie von Willrodt et al. beschrieben [181], behoben werden.

Ein weiterer Kritikpunkt der Untersuchungen ist, dass nicht alle potentiell möglichen Symbole und Farben evaluiert wurden. Die Ergebnisse und Schlussfolgerungen treffen daher v.a. auf die untersuchten Zeichen zu. Weitere, nicht untersuchte Symbole oder Farben können eine höhere Intuitivität oder Verständlichkeit aufweisen. So zeigt der Vergleich von Symbol C2 und C3 der Onlinestudie, dass kleine Details wie das Hinzufügen eines Zebrastrreifens einen großen Einfluss (offene Antworten: +7,3%; vorgegebene Antworten: +25,3%) auf die Verständlichkeit haben können. Außerdem werden bspw.

die Symbole 16, 20, 26 und D1 teilweise so gedeutet, dass der dargestellte Fußgänger vom Fahrzeug wegläuft, weil er am Bildrand nach außen gewandt dargestellt wurde. Diese Darstellung der Fußgänger sollte daher im Symbol horizontal gespiegelt dargestellt werden.

Darüber hinaus könnten beim Vergleich bzw. der Berechnung einer Kovarianz der am Fahrzeug und mittels eines Notebooks bestimmten Erkennungsraten Scheinkorrelationen auftreten. Beide Fragestellungen wurden von den gleichen Probanden in einer festgelegten Abfolge beantwortet. Dadurch könnten in den Daten Lerneffekte enthalten sein.

Die Untersuchung der Bildschirmfarbwiedergabe zeigt, dass die ausgewerteten Displays durchschnittlich den sRGB-Farbraum sehr genau abbilden. In Einzelfällen kann die farbliche Abweichung jedoch höher sein, v.a. wenn benutzerdefinierte Einstellungen der Probanden berücksichtigt werden (z.B. Farbverschiebungen, monochrome Bildschirmwiedergabe oder Gammakorrekturen). Dadurch ist es möglich, dass den Probanden nicht die gewählten, sondern nach Fortner und Meyer [173] signifikant andere Farben gezeigt werden.

Zuletzt soll noch auf die aktuelle Zulassungsfähigkeit der untersuchten Zeichen hingewiesen werden. Wie in Kapitel 2.1.2 beschrieben, sind derzeit Konzepte zur Fahrzeug-Fußgänger-Kommunikation in Arbeit, doch besteht keine gesetzliche Grundlage für die Darstellung der untersuchten Zeichen. Dies betrifft sowohl die evaluierten Dynamiken und Symbole, als auch die Farben aus der Onlinestudie. Aktuell ist es also nicht möglich die Fahrzeug-Fußgänger-Kommunikation wie vorgestellt umzusetzen, weil erst eine Gesetzesänderung notwendig ist. Die hier vorgestellten Untersuchungen könnten als Grundlage für Diskussionen in Zulassungs- und Standardisierungsgremien dienen.

---

## KAPITEL 5

# FAHRERINTENTIONSERKENNUNG MITTELS DEEP LEARNING

Dieses Kapitel beschreibt die Entwicklung eines Algorithmus zur Fahrerintentionserkennung. Dazu werden einleitend Anwendungsbeispiele für die Fahrerintentionserkennung ausgeführt und daraus die Anforderungen an das System definiert. Anschließend wird die Entwicklung des Algorithmus dargestellt, wobei zuerst die verwendeten Daten sowie das dazugehörige Labeling und anschließend die Struktur des Algorithmus beschrieben werden. Zuletzt werden die Ergebnisse dieses Kapitels dargestellt und diskutiert.

Die in dieser Arbeit beschriebene Entwicklung eines Algorithmus zur Fahrerintentionserkennung mittels ANNs (vgl. Kapitel 2.4) beruht v.a. auf der Zusammenstellung eines geeigneten Datensatzes, dem Finden einer Netzwerktopologie und Interpretation der Prädiktion. Der implementierte, dreistufige Algorithmus wird auf Daten einzelner Fahrer angepasst, um möglichst genaue Vorhersagen der Intention der jeweiligen Person treffen zu können. Die nachfolgend dargestellten Ergebnisse beruhen teilweise auf den Ausarbeitungen von Prösl, Höß, Schleyer und Attia [67][182][183][184] sowie drei Veröffentlichungen [164][165][185], die im Rahmen dieser Arbeit erstellt wurden. Insbesondere beruht die Generierung der Datensätze auf Prösl [67] und Schleyer [183], der Aufbau des Algorithmus und Auswahl der relevanten Features auf Höß [182] und das Transfer Learning, Trainieren bzw. Personalisierung der Machine Learning Algorithmen auf Schleyer [183] und Attia [184].

Die Entwicklung eines Algorithmus zur Fahrerintentionserkennung ist eine Möglichkeit, Zeichen mit geringer Intuitivität (siehe Kapitel 4) in einer Übergangsphase vom „manuellen“ zum automatisierten Fahren zu lernen. Außerdem kann der Algorithmus als Wegbereiter für eine unterstützende

---

Kommunikation beim „manuellen“ Fahren eines Fahrzeugs eingesetzt werden. Dadurch kann die Nutzungshäufigkeit der neuartigen Kommunikationsmittel erhöht und eine sichere und verständliche Kommunikation mit Fußgängern umgesetzt werden. Vor allem bei schlechten Sichtverhältnissen bietet eine lichtbasierte Kommunikation Vorteile beim Erkennen der Zeichen.

## **5.1. ANFORDERUNGEN AN EINE FAHRERINTENTIONSERKENNUNG**

Nachfolgend sollen für den zu entwickelnden Algorithmus der Fahrerintentionserkennung Anforderungen definiert werden. Diese werden v.a. durch die Zielanwendung beeinflusst, da für verschiedene Applikationen unterschiedlich kritische Fehlerfälle zu berücksichtigen sind. Die Definition der Anforderungen beruht dabei teilweise auf der Ausarbeitung von Höß [182] und einer Veröffentlichung [164], die im Rahmen dieser Arbeit entstand.

### **5.1.1. ANWENDUNGSBEISPIELE FÜR DIE FAHRERINTENTIONSERKENNUNG**

Wie oben beschrieben bestimmen die Anwendungsfälle die möglichen Fehlerfälle der Fahrerintentionserkennung und deren Auswirkung auf das Umfeld des Fahrzeugs. Im Speziellen ist das Ziel des Algorithmus zu präzisieren, ob ein Fahrer eines Fahrzeugs anhalten möchte oder nicht, bzw. ob das Fahrzeug in einem nachfolgenden Zeitintervall anhalten wird. Deshalb sollen im Folgenden Beispiele für den Einsatz der Fahrerintentionserkennung aufgezeigt werden. Diese beschränken sich nicht auf Anwendungen in automatisierten Fahrzeugen, sondern beziehen auch weitere Beispiele mit ein. Damit können möglicherweise strengere Anforderungen des Algorithmus für diverse Anwendungsbeispiele übernommen werden, ohne dass die später umgesetzte Fahrerintentionserkennung weiterer Anpassungen bedarf.

Ein erstes Anwendungsbeispiel für die Fahrerintentionserkennung ist das Erkennen eines Anhaltens bei der Fahrt auf einer Autobahn. Weil auf Autobahnen, abgesehen von Notfallsituationen, ein allgemeines Park- und Halteverbot besteht, kann eben ein solcher Notfall durch Prädiktion der Fahrerintention frühzeitig erkannt werden. In diesem Fall könnte automatisch eine Warnfunktion, z.B. Warnblinklicht, aktiviert werden, noch bevor das Fahrzeug zum Stehen gekommen ist. Als Ausnahme zu diesem Beispiel ist der Stau zu nennen, da auch hier das Fahrzeug zum Stehen kommt, jedoch keine Gefahr vorliegt. Häufig wird aber auch beim erstmaligen Erkennen des Staus von vielen Verkehrsteilnehmern das Warnblinklicht als Hinweis auf die langsam fahrenden Fahrzeuge aktiviert, was insbesondere durch §16 StVO Abs. 2 geregelt ist [186]. Zusätzlich kann der Algorithmus über eine Spurerkennung oder Abstandssensorik plausibilisiert werden, um so die meisten Fehlerfälle auszuschließen. Bei Nichterkennen der Situation (FN-Klassifikation, vgl. Abbildung 2.4) würden andere Verkehrsteilnehmer keinen Sicherheitsverlust erfahren, da nicht davon auszugehen ist, dass in naher Zukunft alle Fahrzeuge mit dem beschriebenen System ausgestattet sind. Bei einer FP-Klassifikation (vgl. Abbildung 2.4), also dem Erkennen des Anhaltens ohne, dass der Fahrer stehen bleiben möchte, werden andere Verkehrsteilnehmer auf eine Gefahr hingewiesen und verhalten sich wahrscheinlich vorsichtiger als ohne Anzeige des Warnblinklichts. Aus keinem der beiden Fehlerfälle kann eine akute Gefahr für andere Verkehrsteilnehmer abgeleitet werden.

Als weiterer Anwendungsfall kann eine Verbesserung des automatischen Start-Stopp Systems durch frühzeitige Prädiktion des Fahrerverhaltens erreicht werden. So könnte vor dem Abschalten des Motors bei Unterschreitung einer bestimmten Geschwindigkeit, z.B.  $7 \text{ kmh}^{-1}$ , die Intention des Fahrer anzuhalten genutzt werden, um den Aus-Zyklus des Motors zu verlängern und somit noch mehr Energie und Emissionen zu sparen [187]. Sowohl im Falsch-negativ- als auch im Falsch-positiv Fall besteht keine Gefahr für andere Verkehrsteilnehmer und es ist höchstens ein Komfortverlust für den Fahrer zu erwarten.

Ein weiteres Anwendungsbeispiel der Fahrerintentionserkennung ist eine prädiktive Gangschaltung. Bei einem Automatikgetriebe kann durch frühzeitiges Erkennen der Anhalteintention bereits ein niedrigerer Gang eingelegt werden,

um die Bremswirkung des Motors besser auszunutzen. Bei Elektrofahrzeugen kann stärker rekuperiert werden. Gleichmaßen kann für manuelle Getriebevarianten eine entsprechende Schaltempfehlung abgegeben werden. Wie auch beim Start-Stopp System führt jeder Fehlerfall zu einem Komfortverlust für den Fahrer, aber zu keiner akuten Gefahr für andere.

Zuletzt kann der Algorithmus zur Prädiktion der Anhalteintention für die Kommunikation mit anderen Verkehrsteilnehmern eingesetzt werden. Besonders die Kommunikation mit Fußgängern ist ein wichtiger Anwendungsfall (siehe Kapitel 3.2). Die im heutigen Straßenverkehr häufig mehrdeutige Kommunikation [4] kann durch weitere Signalisierungen ergänzt bzw. vereinheitlicht werden. Außerdem kann das System als Vorbereitung zum automatisierten Fahren und die zukünftigen Fahrzeugsignale genutzt werden, um diese in der Bevölkerung einzuführen (vgl. Kapitel 6.2.2). Notwendige Nachrichten einer Fahrzeug-Fußgänger-Kommunikation sind bspw. das Erkennen eines Fußgängers und das Gewähren der Vorfahrt. Bei einer Falsch-Negativ (FN)-Klassifikation verhält sich das Fahrsystem wie bisherige Fahrzeuge und zeigt die gewünschten Kommunikationsinhalte nicht an. Hier entsteht durch Wegfall der zusätzlichen Kommunikation lediglich ein Komfortverlust für andere Verkehrsteilnehmer bzw. die Signale werden von den Beteiligten nicht in einem geistigen Modell mit der vorliegenden Situation verknüpft. Bei einer Falsch-Positiv (FP)-Klassifikation wird beispielsweise ein Zeichen zum Erkennen eines Fußgängers oder dem Vorfahrt gewähren angezeigt, obwohl der Fahrer nicht anhalten möchte. Hier entsteht ein Sicherheitsrisiko für alle Beteiligten, welches dringend zu unterbinden ist. Vor allem für Fußgänger könnten fatale Folgen entstehen.

Der zuletzt beschriebene Anwendungsfall, der auch in dieser Arbeit behandelt wird, ist der kritischste unter den genannten Einsatzmöglichkeiten und soll daher als Referenz für die weiteren Betrachtungen herangezogen werden.

### 5.1.2. ANFORDERUNGEN AN DAS SYSTEM

Die Zuverlässigkeit und Erkennungsrate des Systems zur Fahrerintentionserkennung an Fußgängerüberwegen hängen von mehreren Einflussfaktoren ab. Diese sind z.B. die Definition des Anhaltens des Fahrzeugs und der Prädiktionshorizont, also die Zeit, wie lange vor einer tatsächlich feststehenden Intention des Fahrers anzuhalten, diese prädiziert werden soll. Weitere entscheidende Einflussgrößen sind die Richtig-positiv (RPR) bzw. Falsch-positiv Raten (FPR) der Klassifikation und die gewählte Teststrecke.

Weil beim Überqueren einer Straße heute der Blickkontakt die häufigste Form der Kommunikation zwischen Fahrer und Fußgänger ist (vgl. Kapitel 3.1), soll diese Interaktion als Maßstab für die Anforderung an das System dienen. Ein Blickkontakt kann nach Scarl auf eine durchschnittliche Distanz von  $6\text{ m}$  erkannt werden, wobei typische Abstände von bis zu  $8\text{ m}$  erreicht werden [94]. In dieser Arbeit soll deshalb eine maximale Distanz von  $x_s = 8\text{ m}$  berücksichtigt werden. Daraus lässt sich der Prädiktionshorizont bzw. der Zeitbereich  $T_A$  bestimmen, wie lange vor dem Anhalten das System die Fahrerintention prädizieren kann.

Der Zeitbereich  $T_A$  beschreibt die Zeit einer Verzögerung des Fahrzeug bis zum vollständigen Stillstand über eine Strecke von:

$$x_b = x_s - x_a - x_f = 5,5\text{ m} \quad (5.1)$$

Hier sind  $x_a = 1\text{ m}$  der Abstand zum Fußgängerüberweg und  $x_f = 1,5\text{ m}$  die Länge von Fahrerposition bis Fahrzeugfront, wo die Displayflächen angebracht werden (siehe Abbildung 5.1). Zusätzlich ist der Startpunkt der Verzögerung  $x_0 = 0\text{ m}$ . Nach Bella et al. kann bei Anwesenheit von Fußgängern im innerstädtischen Bereich eine mittlere Verzögerung von  $a = -2,62\text{ ms}^{-2}$  angenommen werden [87]. Mit der zurückgelegten Strecke während der Verzögerung

$$x_v = x_0 + v_0t + \frac{1}{2}at^2 \quad (5.2)$$

und  $v_0 = -at$  ergibt sich die Zeit bis zum vollständigen Stillstand zu:


$$T_A = \pm \sqrt{2 \cdot \frac{x_0 - x_v}{a}} \quad (5.3)$$



Aus Gleichung 5.3 und den oben genannten Größen folgt:

$$T_A = \sqrt{2 \cdot \frac{0 \text{ m} - 5,5 \text{ m}}{-2,62 \text{ ms}^{-2}}} = 2,0 \text{ s} \quad (5.4)$$

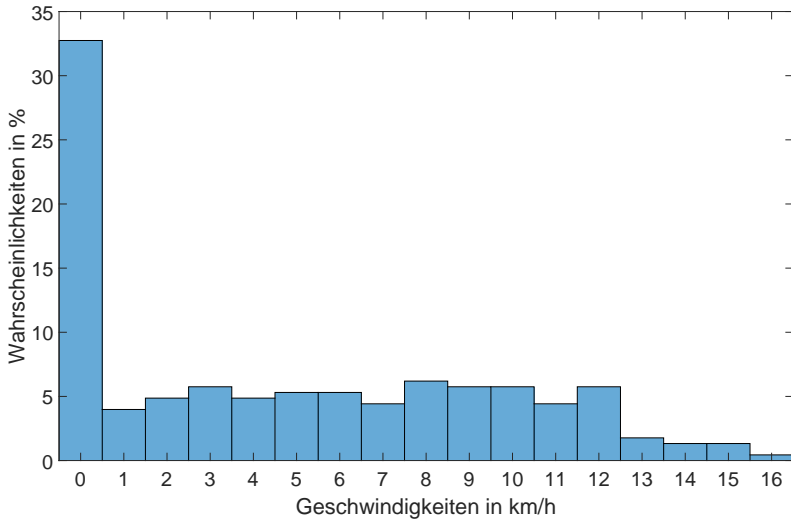
Dieser Zeitbereich von  $T_A = 2,0 \text{ s}$  soll als minimaler Prädiktionshorizont verwendet werden.



**Abbildung 5.1.:** Blickkontakt zwischen Fahrer und Fußgänger in einer Anhaltesituation [164]

Einschränkend ist bei der Definition von  $T_A$  zu bemerken, dass an Fußgängerüberwegen häufig kein Stillstand des Fahrzeugs erreicht wird [30][86][165]. In einer Analyse von ca. 200 Zeitreihen eines Geschwindigkeitssignals an Fußgängerüberwegen beträgt die mittlere minimale Geschwindigkeit beim Anhalten  $5,05 \text{ kmh}^{-1}$ . Lediglich in 32,7% wird ein Stillstand ( $0 \text{ kmh}^{-1}$ ) erreicht (vgl. Abbildung 5.2) [165]. Höhere Start- und Zielgeschwindigkeiten an einem Fußgängerüberweg führen zu einem geringeren Zeitbereich, in dem die heutige Kommunikation mittels Blickkontakt stattfinden könnte. Damit ist der Prädiktionshorizont von  $T_A = 2,0 \text{ s}$  für alle potentiellen Interaktionen zwischen Fahrzeug bzw. Fahrer und Fußgänger ausreichend lang gewählt.

Weil in den meisten Fällen (ca. 67,3%) kein Stillstand erreicht wird, muss auch das Anhalten des Fahrzeugs anders definiert werden. Zur Definition soll das



**Abbildung 5.2.:** Verteilung der minimalen Geschwindigkeiten an Zebrastreifen, nach [165]

Start-Stopp System heutiger Fahrzeuge herangezogen werden. Neben hierfür irrelevanten Bedingungen (z.B. Fahrertürschließzustand oder Motortemperatur [188]) wird das Start-Stopp System unter einer Geschwindigkeit von  $7 \text{ kmh}^{-1}$  aktiviert, was einem Anhalten entspricht [187]. Analog soll diese Geschwindigkeitsschwelle als Plausibilisierung für die Prädiktion des Anhaltens herangezogen werden.

Mit der Definition für ein Anhalten und der Zeit bis zum Stillstand des Fahrzeugs  $T_A$  kann die erforderliche Genauigkeit der Klassifikation festgelegt werden. Nach Omerbegovic sollen mindestens eine Richtig-positiv Rate von 95 % und höchstens eine Falsch-positiv Rate von 5 % erreicht werden, welche auch für diese Arbeit als Anforderung an das System bestimmt werden. Omerbegovic beschreibt eine ähnlich kritische Anwendung zur Empfehlung eines Überholvorgangs, welche bei einer FN-Klassifikation zu einem Komfortverlust, bei einer FP-Klassifikation zu einem erheblichen Sicherheitsrisiko führen würde [189].

### 5.1.3. KRITISCHE BEWERTUNG DER ANFORDERUNGEN

Für die oben beschriebenen Anforderungen können zwei Hauptkritikpunkte angeführt werden. Als erstes wird das Anhalten hier allgemein von der Start-Stopp Funktion abgeleitet und spiegelt nicht die subjektive Wahrnehmung oder Intention des Fahrers wieder. Das Fahrverhalten kann sich für unterschiedliche Fahrer signifikant unterscheiden und somit auch die minimale Geschwindigkeit beim Vorfahrt gewähren an Fußgängerüberwegen. Der zweite Kritikpunkt ist die nach Omerbegovic definierte Richtig-positiv und Falsch-positiv Rate. Vor allem vor dem Hintergrund, dass eine Falsch-positiv Klassifikation ein Sicherheitsrisiko für den Fahrer und andere Verkehrsteilnehmer darstellt, ist diese Falsch-positiv Rate von 5 % hoch angesetzt.

## 5.2. DATENSATZ UND LABELING DER DATEN

Der Aufbau eines geeigneten Datensatzes spielt sowohl beim Trainieren (vgl. Kapitel 2.4.2) als auch beim Absichern (vgl. Kapitel 3.4) eines Machine Learning Algorithmus eine entscheidende Rolle. Der zugrundeliegende Aufbau des dreistufigen Algorithmus wird in Kapitel 5.3 beschrieben und besteht aus einem neuronalen Netzwerk, einem Random Forest und einer Plausibilisierung mittels eines Regelsatzes. Der Datensatz sollte dabei möglichst divers sein und potentielle Anwendungsfälle so genau wie möglich abbilden [39]. Zur Umsetzung einer Fahrerintentionserkennung ist es deshalb vorteilhaft, wenn ausschließlich Realfahrdaten verwendet werden.

### 5.2.1. DATEN FÜR DAS VORTRAINIEREN


Audi sammelt während der Entwicklung jedes neuen Fahrzeugs in der Breitenprobung verschiedene Daten in einer zentralen Datenbank, welche als Grundlage für den erstellten Datensatz dienen. Aus der zentralen Datenbank

rainCOAT (refreshed and improved new CANoe Offline Automation Tester) werden für die vorliegende Arbeit Busdaten (FlexRay) aller Fahrzeuge der ML-BevoGen2 (Modularer Längsbaukasten Evolution Generation 2) Plattform, u.a. A6, A7, A8 und Q8, exportiert. Diese sind zum Zeitpunkt der Datenaufnahme bei Audi die höchstklassigen Fahrzeugmodelle mit Verbrennungsmotor. Insgesamt werden 7114 Datenreihen mit einer Länge von je 60 s und einer Auflösung von 10 ms aus dem Zeitraum April 2017 bis Mai 2018 berücksichtigt. Damit stehen rund 119 Stunden Datenmaterial zur Verfügung. Die Zeitreihen umfassen 91 vorausgewählte Signale, jeweils 30 s vor bzw. nach dem Erkennen eines Zebrastreifens, wobei die zeitliche Auflösung der Signale zwischen 10 ms und 200 ms liegt. Bei Signalen mit einer geringeren zeitlichen Auflösung als 10 ms findet eine Überabtastung statt.

Die Zebrastreifen werden über eine Verkehrszeichenerkennung identifiziert, da in dieser Fahrzeugarchitektur und mit der verwendeten Kameraauswertung keine Möglichkeit besteht, Zebrastreifen direkt zu erkennen. In der Mitte der aufgenommenen Zeitsequenzen befindet sich also genau der Punkt, bei dem das Fahrzeug zum ersten Mal einen Zebrastreifen erkannt hat. Das Anhalten und damit auch der Zebrastreifen ist daher stets später in der Sequenz zu beobachten. Mit diesem Vorgehen der Situationserkennung werden ausschließlich Sequenzen um Zebrastreifen aufgenommen, wobei jedoch auch Zebrastreifen nicht erkannt werden könnten. Ist beispielsweise das entsprechende Verkehrsschild am Zebrastreifen zu stark verschmutzt oder gibt es ein solches überhaupt nicht, so würde keine Datenreihen aufgezeichnet werden. Die Erkennungsgenauigkeiten moderner Algorithmen zur Verkehrszeichenerkennung sind mit ca. 99 % vergleichbar mit der von Menschen und damit auch nahezu fehlerfrei. Deshalb kann davon ausgegangen werden, dass auch unter verschiedenen Witterungseinflüssen, Tageszeiten und bei Teilverdeckungen der Verkehrszeichen nahezu alle Schilder für Zebrastreifen erkannt werden [190]. Dadurch könnte einerseits die Gesamtzahl der passierten Zebrastreifen von der Zahl der aufgenommenen Datenreihen abweichen, andererseits ist die Menge der Datenbeispiele für das Training des Algorithmus zur Fahrerintentionserkennung ausreichend groß. In 1114 aus 7114 aufgenommenen Datenreihen verzögert das Fahrzeug am Zebrastreifen deutlich, um Fußgänger die Straße überqueren zu lassen. In allen übrigen Datenreihen wird zwar

ein Zebrastreifen mittels Verkehrszeichenerkennung erkannt, aber es befindet sich kein Fußgänger am Zebrastreifen bzw. das Fahrzeug hält nicht an.

Wie in Kapitel 2.3 beschrieben, muss für ein überwachtes Lernen jedem Trainingsdatenvektor  $x$  ein Label  $y$  zugeordnet werden. Für die Verarbeitung im ersten Teil des Algorithmus (vgl. Kapitel 5.3) wird das Label für eine Zeitreihe der Eingangssignale (siehe Abbildung 5.3, blau und rot) durch eine darauffolgende Sequenz (siehe Abbildung 5.3, grün) festgelegt. Der rote Datenpunkt aus Abbildung 5.3 ist der letzte Datenpunkt der Trainingssequenz und stellt damit den aktuellen, zuletzt aufgenommenen Zeitpunkt dar. Für die 35 Datenpunkte jedes Trainingsvektors (vgl. Kapitel 5.3) werden alle Zeitpunkte der Sequenz mit der Taktrate  $\tau_{tr} = 100\text{ ms}$  verwendet, um nicht zu viele, sehr ähnliche Datenreihen zu erzeugen, aber trotzdem einen möglichst großen Datensatz zu erhalten. Für die fünf Testvektoren (vgl. Kapitel 5.3) wird jeder vierte Datenpunkt mit einer resultierenden Taktrate von  $\tau_{te} = 400\text{ ms}$  betrachtet, wodurch sich neben der Länge der prädizierten Ausgangsmatrix  $\hat{y}$  auch die Komplexität der Prädiktion verringert. Diese Reduktion der Auflösung von Trainings- und prädizierten Daten bzw. die damit geringere, zu verarbeitende Datenmenge ist notwendig, um den Algorithmus schneller trainieren und den Klassifikator im Fahrzeug betreiben zu können. Die Signalwerte mit einer geringeren zeitlichen Auflösung werden dupliziert (z.B. Verkehrszeichenerkennung) und Signale mit höherer zeitlicher Auflösung (z.B. Geschwindigkeit) werden mittels Downsampling an die Taktrate  $\tau_{tr} = 100\text{ ms}$  angepasst. Alle unberücksichtigten Datenpunkte einer Zeitsequenz sind in Abbildung 5.3 weiß dargestellt.




**Abbildung 5.3.:** Beispiele für die Aufteilung der Trainings- (blau, rot) und Testdaten (grün)

Um eine größere Anzahl an Datensätzen für das Training des ANN zu erhalten, wird über Data-Augmentation [39] der Datensatz künstlich erweitert. Dazu startet das Fenster für eine Trainingssequenz nicht nach der vorhergehenden, sondern bereits nach  $\tau_s = 500 \text{ ms}$ , bzw. fünf Datenpunkten, während der vorhergehenden Zeitreihe. Durch diese Wahl von  $\tau_s$  und  $\tau_{te}$  treten nahezu keine Überschneidungen der prädierten Zeitschritte der Sequenzen im erweiterten Datensatz auf. Aus jeder Sequenz mit einer Länge von 60 s lassen sich somit 110 Datenreihen aufbauen, wodurch der gesamte Datensatz insgesamt 782.540 Zeitreihen umfasst.

Im zweiten Teil des Algorithmus (vgl. Kapitel 5.3) werden die Daten teilweise automatisiert gelabelt. Dazu wird unter Berücksichtigung aller Datenpunkte zunächst ein Regelsatz erstellt (siehe Anhang B.1), welcher die Zeitreihen der Ausgangsdaten des ersten Teils und den letzten Datenpunkt der Eingangssequenz (siehe Abbildung 5.3, grün und rot) automatisiert einer Fahrerintention zuordnet. Diese 39 manuell erstellten Regeln, welche ähnlich wie ein Decision Tree aufgebaut sind (vgl. Kapitel 2.7), resultieren entweder in der Intention „Fahrer möchte anhalten“ oder „Fahrer möchte nicht anhalten“. Damit werden die zur Verfügung stehenden Sequenzen automatisiert einem Label zugeordnet. Durch das Bilden der 39 Regeln wird versucht die Daten objektiv, standardisiert und gleichmäßig zu Labeln.

Um ein noch genaueres Labeln der Daten mit der jeweiligen Fahrerintention zu erreichen, werden die Entscheidungsschwellen der teilweise automatisiert gelabelten Daten durch Trainieren eines Decision Trees generalisiert. Hierfür werden drei Decision Trees variabler Tiefe mit unterschiedlich großen Teilen der durch die Regeln klassifizierten Daten trainiert. Die restlichen Daten werden zum Validieren des Ergebnisses verwendet. Wie in Abbildung 5.4 zu sehen ist, flachen die Accuracies der Decision Trees ab einer Tiefe von ca. neun ab. Dieser Punkt kann mit einer Accuracy von ca. 0,99 als guter Kompromiss zwischen exakter Wiedergabe und generalisierter Deutung der Fahrerintention angenommen werden. Diese Annahme wird durch manuelles Überprüfen von jeweils 100 RPs und FPs durch zwei Personen abgesichert. Die beiden Experten bewerten die fälschlicherweise positiv klassifizierten Zeitsequenzen zu ca. 54 % als eigentlich korrekte Klassifikation. Dies zeigt, dass der Decision Tree die wahre Fahrerintention sehr gut wiedergibt, auch



**Abbildung 5.4.:** Accuracy des Decision Trees für das generalisierte Labeln der Daten, nach [182]

wenn v.a. beim Übergang von „Fahrer möchte anhalten“ und „Fahrer möchte nicht anhalten“ die Entscheidung der beiden Experten nicht immer konsistent ist. Dadurch wird deutlich, dass die Fahrerintention sehr subjektiv und nur schwer zu generalisieren ist. Die von dem Decision Tree generierten Label werden für die Implementierung des Algorithmus als wahre Intention des Fahrers angenommen.

### 5.2.2. VERWENDETE FEATURES

Aus den 91 vorausgewählten und potentiell relevanten Signalen als Features für die Fahrerintentionserkennung (siehe Anhang B.2) werden die wichtigsten Features ausgewählt. Dies ist neben der Reduktion der Komplexität, was schnellere Trainings- und Klassifikationszyklen ermöglicht, auch für die Sicherheit von datenbasierten Algorithmen notwendig (vgl. Kapitel 3.4).

Bevor passende Features für das neuronale Netz ausgewählt werden, werden diese vorverarbeitet. Die Features `LWI_Lenradwinkel` und `LWI_Lenradw_Geschw` beschreiben jeweils den Absolutwert des Lenradwinkels sowie der Lenradwinkelgeschwindigkeit und werden unabhängig von deren Vorzeichen `LWI_VZ_Lenradwinkel` und `LWI_VZ_Lenradw_Geschw` aufgezeichnet. Durch Zusammenfassen der beiden Signale mit dem jeweiligen Vorzeichen werden neue, vorzeichenbehaftete Features gebildet. Die zehn diskreten Signale `BV2_Obj_X_Klasse` geben die Klasse des erkannten Verkehrsteilnehmers für eines der zehn Objekte wieder. Diese Signale unterscheiden 13 verschiedene Verkehrsteilnehmertypen. Für den hier vorgestellten Algorithmus ist die Information ausreichend, ob ein motorisiertes Fahrzeug (MOT, z.B. PKW, Motorrad) oder schwacher Verkehrsteilnehmer (VRU, vulnerable road user, z.B. Fußgänger, Radfahrer) erkannt wird. Deshalb wird jedes der zehn Merkmale durch zwei binäre Features `CamObjX_MOT` und `CamObjX_VRU` ersetzt. Die Signale `VZE_Verkehrszeichen_X` beinhalten die diskrete Information, welches Verkehrszeichen jeweils erkannt wird. Da in dieser Arbeit die meisten Verkehrszeichen irrelevant sind (z.B. Baustelle, Weghinweis-, Parkhinweisschilder), wird das Signal durch ein binäres Feature für die Erkennung von fußgängerrelevanten Verkehrszeichen ersetzt (`Zebra`streifen, `Warnhinweis` Fußgänger). Durch diese Schritte erhöht sich die Anzahl der potentiell relevanten Features von 91 auf 99.

Mit einem Verfahren nach Ruck et al. [191] werden die zu verwendenden Features mit Hilfe eines ANNs ausgewählt. Weil das Netzwerk ausschließlich zur Wahl der relevanten Features verwendet wird, ist eine flache Architektur ausreichend. Hierfür werden zwei verdeckte Schichten mit 50 und 20 Neuronen, jeweils mit logistischen Sigmoidfunktionen als Aktivierungsfunktion sowie einer Eingangsschicht mit variabler Größe verwendet. Die Anzahl der Eingänge wird während der iterativen Merkmalsauswahl verändert. Die Ausgangsschicht enthält fünf Neuronen für die im Random Forest verwendeten Features (vgl. Kapitel 5.3). Die unterschiedlichen Eingangsgrößen erstrecken sich über verschiedene Größenordnungen, weshalb die erlernten Gewichte unterschiedlich hohe Auswirkungen auf den Ergebnisvektor haben. Deshalb werden alle Eingänge mit Hilfe einer Tanh Normalisierung vorverarbeitet (vgl. Kapitel 2.4.3).



Nach Ruck et al. [191] wird mit den gespeicherten Aktivierungen jeder Schicht des oben beschriebenen Netzwerks und der Zuhilfenahme der Kettenregel der Einfluss  $\Lambda_j$  eines jeden Features  $j$  auf den Ausgangsvektor  $\hat{y}$  bestimmt. Aus der logistischen Sigmoidfunktion berechnet sich die Ableitung dieser in Neuron  $a$  und Schicht  $b$  folgendermaßen [191]:

$$\delta_{ab} = x_{ab}(1 - x_{ab}) \quad (5.5)$$

$x_{ab}$  ist der Ausgang des Neurons  $a$  in Schicht  $b$ . Damit gilt für das oben beschriebene Netzwerk und Ausgangsneuron  $i$  sowie Eingangsmerkmal  $j$ :

$$\frac{\partial \hat{y}_i}{\partial x_j} = \delta_{i3} \sum_m W_{mi3} \delta_{m2} \sum_n W_{nm2} \delta_{n1} W_{jn1} \quad (5.6)$$

Hierbei stellt  $W_{cdb}$  das verbindende Gewicht zwischen den Neuronen  $c$  in Schicht  $b - 1$  und  $d$  in Schicht  $b$  dar. Damit lässt sich der Einfluss eines Features auf eine Ausgangsgröße bestimmen. Um den gesamten Einfluss eines Features  $j$  zu bestimmen wird  $\Lambda_j$  für Datenvektoren  $x$  in einem Datensatz  $S$  folgendermaßen berechnet [191]:

$$\Lambda_j = \sum_{x \in S} \sum_i \left| \frac{\partial \hat{y}_i}{\partial x_j}(x, W) \right| \quad (5.7)$$

$W$  ist dabei die Gewichtsmatrix des Netzwerks.

Um die Relevanz der einzelnen Features für den Ausgang bewerten zu können, werden sie mit drei weiteren Merkmalen verglichen. Diese sind eine Konstante 1, ein gaußsches und ein weißes Rauschen. Das Netzwerk wird in jedem Iterationsschritt zehnmal trainiert, um Initialisierungseffekte zu minimieren. Immer wenn ein Feature gemittelt über diese zehn Durchläufe einen signifikant größeren Einfluss  $\Lambda_j$  auf den Ausgangsvektor vorweist (t-Test;  $\alpha = 0,95$ ;  $p < 0,05$ ), wird es für den nächsten Iterationsschritt berücksichtigt. Zusätzlich soll der mittlere Rang des Features höher sein als jeder der Referenzmerkmale. Als relevant werden die Features bezeichnet, die diese beiden Kriterien in jedem Durchlauf erfüllen.

Das beschriebene Verfahren wird auf einen Teil des Datensatzes angewendet und es konvergiert nach vier Iterationsschritten. Fünf verschiedene Prädiktionshorizonte von 1 s bis 10 s werden untersucht, um eine größere Menge

relevanter Features zu erhalten. Die oben beschriebenen Bedingungen müssen für mindestens einen der Zeithorizonte erfüllt sein, wodurch letztlich 22 Signale als relevant gekennzeichnet werden. Die Ergebnisse sind in Tabelle 5.1 dargestellt. Der MSE steigt über die vier Iterationsschritte im Mittel um 4,76%, was mit der Verringerung der Features und damit der dem Netzwerk zur Verfügung stehenden Informationen zusammenhängt.

**Tabelle 5.1.:**

Feature Auswahl mittels ANN, nach [182]


Iteration	Features	$MSE_{1s}$	$MSE_{1,5s}$	$MSE_{3s}$	$MSE_{5s}$	$MSE_{10s}$
1	99	0,0116	0,0173	0,0299	0,0386	0,0501
2	32	0,0117	0,0174	0,0302	0,0391	0,0511
3	26	0,0118	0,0179	0,0305	0,0398	0,0522
4	22	0,0122	0,0182	0,0308	0,0406	0,0528

Für die zweite Stufe des Algorithmus (siehe Kapitel 5.3) werden fünf Features als Eingangsgröße ausgewählt. Diese sind Geschwindigkeit, Bremsdruck, Lenkradwinkel sowie Längs- und Querbesehleunigung, welche in den oben beschriebenen Iterationsschritten über alle Prädiktionshorizonte stets sehr relevante Merkmale darstellen. Diese werden deshalb als Ausgangsgröße des RNN und Eingang für den Random Forest verwendet. Zusätzlich werden dem ausgewählten Random Forest noch Minimum, Maximum, Mittelwert und Standardabweichung dieser Signale zur Verfügung gestellt.

### 5.2.3. DURCHSCHNITTLICHE GESCHWINDIGKEITSPROFILE AN ZEBRASTREIFEN

Der aufgebaute Datensatz für das Vortrainieren aus der rainCOAT Datenbank enthält Fahrprofile verschiedener Fahrer in der unmittelbaren Nähe von Zebrastreifen. Diese ermöglichen einen Einblick in das durchschnittliche Fahrverhalten bei Anwesenheit von Fußgängern, wobei vor allem Geschwindigkeitsprofile das Vorgehen der Fahrer verstehen lassen. 226 zufällig

ausgewählte Datensequenzen, die einen Anhaltvorgang an Zebrastrifen beinhalten, werden für die Analyse der durchschnittlichen Geschwindigkeitsprofile manuell gelabelt. Dazu wird ein Punkt (A) markiert, bei dem das Fahrzeug beginnt zu verzögern und ein Punkt (B), welcher die minimale Geschwindigkeit des Fahrmanövers kennzeichnet (siehe Abbildung 5.5). In Abbildung 5.5 ist zusätzlich eine graue Hilfslinie für  $7\text{ kmh}^{-1}$  eingezeichnet. Diese Geschwindigkeitsschwelle wird in Kapitel 5.1.2 als Stopp-Bedingung definiert.



**Abbildung 5.5.:** Beispiel für Geschwindigkeitsprofil an Zebrastrifen mit Startpunkt (A) und Endpunkt (B) der Verzögerung, nach [165]

Die analysierten Zeitreihen zeigen, dass Fahrzeuge von Startpunkt (A) innerhalb von  $8,19\text{ s}$  auf ihre minimale Geschwindigkeit in Endpunkt (B) verzögern und dabei eine mittlere Strecke von  $47,41\text{ m}$  zurücklegen. Dies stimmt mit Ergebnissen von Schneemann und Gohl [12] sowie von Várhelyi [192] überein. Die durchschnittliche Startgeschwindigkeit in Punkt (A) beträgt  $32,70\text{ kmh}^{-1}$  und die mittlere Minimalgeschwindigkeit  $5,05\text{ kmh}^{-1}$ . Eine Verteilung der minimalen Geschwindigkeiten an Zebrastrifen ist bereits in Kapitel 5.1.2 dargestellt (siehe Abbildung 5.2). Die mittlere Geschwindigkeit beträgt, unter Berücksichtigung des Prädiktionshorizonts von  $2\text{ s}$ , vor dem Erreichen der


Stopp-Bedingung (siehe oben)  $18,64 \text{ kmh}^{-1}$  mit einer Standardabweichung von  $5,37 \text{ kmh}^{-1}$ . Dies ist die mittlere Geschwindigkeit, die ein Fahrzeug beim Erkennen der Fahrerintention an Zebrastrifen aufweist.

#### 5.2.4. DATEN FÜR DAS TRANSFER LEARNING

Wie in Kapitel 2.8 beschrieben ist es vorteilhaft, bestehende Machine Learning Algorithmen an ein spezielles Problem anzupassen. Daher sollen das verwendete RNN und der Random Forest (siehe Kapitel 5.3) an den aktuellen Fahrer des Fahrzeugs angepasst werden, um nicht nur ein durchschnittliches Fahrverhalten zu trainieren, sondern auch individuelle Unterschiede zwischen den Fahrern zu berücksichtigen. Dafür werden für verschiedene Testpersonen separate Datensätze aufgebaut.

Nach der Bundesanstalt für Straßenwesen [193] und dem Kraftfahrt-Bundesamt [194] beträgt die durchschnittliche Fahrleistung deutscher Pkws im Jahr 2014  $13.727 \text{ km}$ , wobei Landstraßen im Jahr 2018 mit ca. 45,5 % die am häufigsten befahrene Straßenart darstellen. Innerorts werden lediglich ca. 26,4 % der gefahrenen Kilometer zurückgelegt, auf Bundesautobahnen ca. 28,1 % [193]. Die Referenzstrecke für die Aufzeichnung personalisierter Trainingsdaten soll sich an dieser Aufteilung orientieren, wobei der Streckenanteil innerorts länger gewählt wird, um mehr Anhaltefälle bzw. Situationen an Fußgängerüberwegen zu erhalten. Dies soll die Skewness (Schiefe) des Datensatzes durch unausgeglichene Klassenzuordnungen reduzieren, um schon mit wenigen aufgenommenen Kilometern möglichst viele der zu untersuchenden Situationen zu erhalten.

Die im Raum Ingolstadt entwickelte Referenzstrecke (siehe Abbildung 5.6) umfasst insgesamt  $36,3 \text{ km}$ , wobei der größte Anteil innerorts aufgenommen wird (ca. 56,2 %). Die Länge der Strecke wird mit Hilfe der Elbow-Methode ermittelt (siehe Anhang B.3 Abbildung B.1). Wie die durchschnittliche Fahrleistung deutscher Pkws (siehe oben), hat auch die Referenzstrecke einen wesentlich höheren Anteil Landstraßen (ca. 31,0 %) als Bundesautobahnen (ca. 12,8 %).



**Abbildung 5.6.:** Referenzstrecke zur Aufzeichnung von personalisierten Trainingsdaten [195]

Für den an einen Fahrer und ein Fahrzeug angepassten Trainingsdatensatz werden die gleichen Features aufgezeichnet, wie oben für die Daten des Vortrainierens beschrieben. Als Referenzfahrzeug für die vier Fahrer wird ein Audi A8L (2018) eingesetzt. Bei den vier Fahrern handelt es sich um eine weibliche und drei männliche Testpersonen.

Diese Referenzstrecke für den fahrer- bzw. fahrzeugspezifischen Trainingsdatensatz umfasst sechs Zebrastreifen, 47 Ampeln, neun Überquerungshilfen für Fußgänger und fünf Kreisverkehre. In dieser Arbeit ist ein fahrer- bzw. fahrzeugspezifischer Datensatz als ein Datensatz definiert, welcher für jeweils einen Fahrer mit einem Fahrzeug aufgenommen wird. Mit zusätzlich 22 Situationen in denen ein Fußgänger- bzw. Fahrradweg gekreuzt wird, sind in dieser Referenzstrecke 94 Situationen enthalten, in denen der Fahrer potentiell mit Fußgängern bzw. schwachen Verkehrsteilnehmern in Kontakt treten kann. Lediglich bei den Überquerungshilfen hat der Fußgänger formell keinen Vorrang vor dem sich annähernden Fahrzeug. Beim Fahren dieser Referenzstrecke halten die vier Fahrer durchschnittlich ca. 100-mal an.



Beim Aufzeichnen der fahrer- und fahrzeugspezifischen Daten sind Unterschiede in den Fahrweisen der Fahrer zu beobachten. Während Fahrer 1, 3 und 4 über die gesamte Referenzstrecke sehr vorausschauend fahren, ist für Fahrer 2 ein anfangs unsicheres und hektisches Fahrverhalten zu beobachten. Nach einer Eingewöhnungsphase von ca. zehn Kilometern ändert sich dessen Fahrweise deutlich und der Proband fährt ab diesem Zeitpunkt ebenfalls vorausschauend.

Die Vorverarbeitung der Datensätze und das Labeling erfolgen analog wie für das Vortrainieren beschrieben.

### 5.2.5. NORMALISIERUNG DER VERWENDETEN FEATURES

Wie in Kapitel 2.4.3 beschrieben, wird empfohlen, die verwendeten Features zu normalisieren, weshalb sie wahlweise mit einer Min-Max bzw. Tanh Normalisierung vorverarbeitet werden.

**Tabelle 5.2.:**

Vergleich Min-Max und Tanh Normalisierung für das RNN57: Absolute Abweichung des prädierten Geschwindigkeitswert zum Label, nach [182]

Feature- satz	Normal- isierung	0-10	10-25	25-40	40-55	55-70	> 70	∅
		$[\frac{km}{h}]$	$[\frac{km}{h}]$	$[\frac{km}{h}]$	$[\frac{km}{h}]$	$[\frac{km}{h}]$	$[\frac{km}{h}]$	
1	keine	6,65	3,92	1,77	1,04	1,47	7,44	2,15
2	keine	5,92	3,34	1,99	1,47	1,42	6,06	2,22
1	Min-Max	1,66	1,32	0,87	0,69	0,84	1,26	0,90
2	Min-Max	2,07	1,48	0,93	0,73	0,87	1,35	0,97
1	Tanh	2,53	1,79	1,20	1,49	3,33	18,54	2,45
2	Tanh	2,13	1,79	1,08	1,18	4,89	21,02	2,58
Testbeispiele [%]		5,2	10,0	27,6	39,9	13,1	4,2	

Tests mit dem RNN57 (siehe Anhang B.4) sowie mit zwei verschiedenen Featureauswahlen und für die beiden Normalisierungsverfahren bzw. ohne

Normalisierung zeigen, dass eine Min-Max Normalisierung stets genauere Ergebnisse liefert als eine Tanh Normalisierung. Diese Ergebnisse sind in Tabelle 5.2 dargestellt. Deshalb wird trotz der Einschränkung, dass die meisten Testbeispiele bei relativ hohen Geschwindigkeiten zwischen 25 und 55  $kmh^{-1}$  liegen, für die weitere Implementierung eine Normalisierung der Daten mittels Min-Max Verfahren durchgeführt.

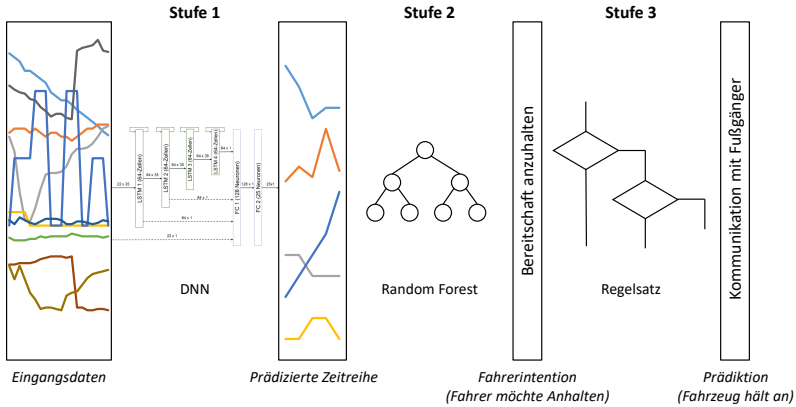
### 5.3. AUFBAU DES ALGORITHMUS

Wie in Kapitel 3.4 beschrieben können Machine Learning Algorithmen mit einer End-To-End Architektur kaum interpretiert werden und sind daher für sicherheitsrelevante Anwendungen nicht zu verwenden. Um den Algorithmus wie oben beschrieben absichern zu können, wird dieser in einzelne Stufen mit jeweils abgegrenzten Aufgaben unterteilt. Dabei wird der aus dem Algorithmus Design bekannte Divide-and-Conquer Ansatz gewählt, bei dem jedes Problem rekursiv in kleinere Subprobleme unterteilt wird. Diese sind einzeln einfacher zu lösen und werden anschließend wieder kombiniert, um das Originalproblem abzubilden [143]. Eine Interpretation des Algorithmus könnte für jeder der drei Stufen einzeln erfolgen. Der Algorithmus lässt sich wie in Abbildung 5.8 dargestellt in drei Stufen unterteilt.

#### 5.3.1. STUFE 1: PRÄDIKTION VON ZEITREIHEN

Recurrent Neural Networks, insbesondere LSTMs sind für die Analyse sequentieller Daten und das Modellieren von zeitlichen Zusammenhängen geeignet (vgl. Kapitel 2.6 und Kapitel 3.5) und werden daher für die Prädiktion einzelner Features der Fahrerintentionserkennung eingesetzt. Das Netzwerk für die Prädiktion von Zeitreihen wird aus mehr als 70 verschiedenen Netzwerken ausgewählt (siehe Anhang B.4). Dafür werden zunächst sieben RNNs anhand der von ihnen erreichten MSE auf einen Testdatensatz ausgewählt. Anschließend werden mit diesen Netzwerken verschiedene Tests zur Robust-

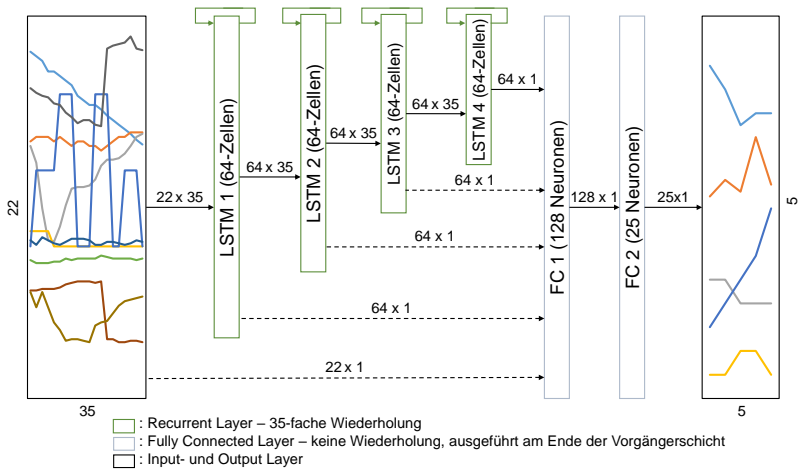




**Abbildung 5.8.:** Aufbau des Algorithmus zur Fahrerintentionserkennung in drei Stufen, nach [164]

heit gegenüber Datenauswahl und Normalisierung durchgeführt, um über eine Rangliste das am besten geeignete RNN auszuwählen (vgl. Höß [182]). Die Architekturen unterscheiden sich in Schichtanzahl, -aufbau und Eingangs- bzw. Ausgangsdaten. Das für diese Arbeit ausgewählte RNN ist in Abbildung 5.9 dargestellt.

Das Netzwerk aus Abbildung 5.9 besteht aus vier LSTM und zwei FC Schichten. Die vier LSTM Schichten mit jeweils 64 Zellen bzw. Zellzuständen dienen dazu, die Sequenz der Eingangsdaten zu verarbeiten und zeitliche Zusammenhänge zu erstellen. Mit Hilfe dieser zeitlichen Zusammenhänge und der FC Schichten werden die Werte der fünf Ausgangssignale im Prädiktionshorizont von 2s vorhergesagt. Die erste LSTM Schicht verarbeitet sequentiell 35 Zeitschritte der Eingangsvektoren, alle nachfolgenden rekurrenten Schichten verarbeiten die Ausgänge der jeweils vorhergehenden. Auch diese umfassen 35 Zeitschritte mit Vektoren der Länge 64, welche durch die Anzahl der Zellzustände pro Schicht festgelegt wird. Die erste FC Schicht besteht aus 128 Neuronen und verarbeitet alle Eingangsdaten sowie die Ausgangsvektoren der vier LSTM Schichten des letzten Zeitschritts. Der Ausgangsvektor der Länge 128 dieser ersten FC Schicht dient als Eingang für die letzte Schicht. Hier werden 25 Werte prädiziert, welche als jeweils fünf Zeitschritte im Prä-



**Abbildung 5.9.:** Aufbau des DNN in Stufe 1, nach [164]

diktionshorizont für die fünf Ausgangssignale (siehe Kapitel 5.2) interpretiert werden können. Das Netzwerk entspricht dem RNN72 aus Anhang B.4.

Das RNN verwendet dabei für jedes der 22 ausgewählten Features (siehe Kapitel 5.2) 35 Zeitschritte bzw. 3,5 s als Eingangsdaten. Diese Länge der Eingangssequenz weist im Bereich von 0,5 s bis 6 s die niedrigste MSE auf (siehe Anhang B.5, Abbildung B.2). Die Ausgangslänge für jedes Signal beträgt 5 Zeitschritte (siehe grüne Zeitschritte in Abbildung 5.3), wobei für die Fahrerintentionserkennung in Stufe 2 zusätzlich der letzte bzw. aktuelle Zeitschritt der Eingangsdaten (siehe roter Zeitschritt in Abbildung 5.3) betrachtet wird.

Eine weitere Analyse verschiedener Aktivierungsfunktionen mit dem zufällig ausgewählten Testdatensatz von Fahrer 4 zeigt, dass eine Kombination aus Tangens hyperbolicus und logistischer Sigmoidfunktion die besten Ergebnisse liefert. Die Auswahl des Testdatensatzes erfolgt dabei zufällig. Tabelle 5.3 verdeutlicht, dass die RPRs für diese Kombination sowohl nach Stufe 2 als auch nach Stufe 3 am höchsten sind, während die FPRs ebenfalls besser oder ähnlich zu den anderen Aktivierungsfunktionen sind. Die Test-MSE ist für die Kombination aus Tangens hyperbolicus in LSTM Schichten und logistische

Sigmoidfunktion in FC Schichten mit  $3,16 \cdot 10^{-4}$  am höchsten, doch liegt sie damit nur ca. 1,0% unwesentlich über der minimalen Test-MSE von  $3,13 \cdot 10^{-4}$ . Auch die Trainingsdauer bzw. Anzahl der notwendigen Trainings-Epochen liegt mit 47 lediglich 4,4% über dem schnellsten Training (45 Epochen). Die Anzahl der Trainings-Epochen spielt hier nur eine untergeordnete Rolle und kann je nach Initialisierung der Gewichtematrix variieren. Damit sind hier bei erneuten Tests andere Anzahlen der Trainingsepochen zu erwarten, während die Genauigkeitsmaße nahezu konstant bleiben sollten. Die mit Abstand schlechtesten Ergebnisse werden mit einer logistischen Sigmoidfunktion für alle Schichten erzeugt.

**Tabelle 5.3.:**

Vergleich verschiedener Aktivierungsfunktionen für das aufgebaute RNN und einen ausgewählten Testdatensatz, nach [184]

LSTM	FC	Epochen Training	MSE	RPR	FPR	RPR	FPR
			Test	Stufe 2		Stufe 3	
			[ $10^{-4}$ ]	[%]	[%]	[%]	[%]
Sigmoid	Sigmoid	162	3,13	17,79	4,91	5,00	5,00
Sigmoid	Tanh	123	3,14	36,81	5,00	5,00	5,00
Sigmoid	ReLU	94	3,15	8,44	4,39	5,00	5,00
<b>Tanh</b>	<b>Sigmoid</b>	47	3,16	97,86	4,27	94,29	1,34
Tanh	tanh	143	3,14	86,54	4,79	80,36	0,01
Tanh	ReLU	142	3,13	78,68	4,74	89,29	5,00
ReLU	Sigmoid	154	3,14	7,65	4,91	5,00	5,00
ReLU	Tanh	45	3,16	9,79	4,78	6,07	5,00
ReLU	ReLU	46	3,16	72,78	4,92	85,00	5,00

Obwohl die Tangens hyperbolicus und ReLU Aktivierungsfunktionen für LSTM und FC Schichten in diesem Test gute Ergebnisse erreichen, sind sie, anders als in der Literatur vermutet, nicht die effektivsten (vgl. Kapitel 2.4.1). Die Ergebnisse hängen, wie in Kapitel 2.3 beschrieben, vom verwendeten Datensatz und der zugrundeliegenden Architektur ab (vgl. No Free Lunch Theorem). Die Grundlagen aus Kapitel 2.4.1 werden insofern bestätigt, als Tangens hyperbolicus Aktivierungsfunktionen in der LSTM Schicht zu höheren RPRs

und niedrigeren FPRs führen. Außerdem bestätigen die Ergebnisse, dass bei Verwendung einer ReLU die Klassifikation negativ beeinflusst werden kann. Die Test-MSE ist bei allen Kombinationen der Aktivierungsfunktionen sehr ähnlich, obwohl die RPRs und FPRs stark variieren. Dies hängt vermutlich damit zusammen, dass die MSE ein kumuliertes Genauigkeitsmaß darstellt, während die RPRs und FPRs verschiedene Eingangsmerkmale unterschiedlich hoch gewichtet einbeziehen. Dadurch können auch niedrigere MSEs zu größeren Fehlern in der Prädiktion führen. Die Klassifikationen nach der dritten Stufe mit RPRs und FPRs von jeweils 5,00%, sind realistische Interpolationen aus der Receiver Operating Characteristic (ROC)-Kurve. Alle Punkte der ROC-Kurve liegen im Koordinatenursprung oder bei jeweils 100%. Dies bedeutet, dass, unabhängig von der verwendeten Schwelle im Random Forest, alle Ergebnisse in den beiden Extrempunkten der ROC-Kurve liegen. Derartige Ergebnisse treten insbesondere bei kleinen Datensätzen auf. Weil andere Klassifikatoren trotzdem sinnvolle Resultate aufweisen, zeigt dies, dass die Klassifikatoren mit einer RPR und FPR von jeweils 5,00% für das untersuchte Problem ungeeignet sind.


### 5.3.2. STUFE 2: FAHRERINTENTIONSERKENNUNG

Die Fahrerintentionserkennung, also die Prädiktion, ob ein Fahrer anhalten möchte, soll mit Hilfe eines Random Forest durchgeführt werden, da diese komplexe Modelle abbilden können und trotzdem interpretierbar sind (vgl. Kapitel 2.7 und 3.4). Außerdem kann mittels Random Forests eine Regression durchgeführt bzw. eine Klassifikationsgenauigkeit ausgegeben werden, wodurch die Prädiktion über einen Schwellwertparameter eingestellt werden kann.

Die Architektur unterschiedlicher Random Forests unterscheidet sich in der Anzahl der verwendeten Bäume und deren Tiefe. Um diese beiden Parameter einstellen zu können, wird ein Trainingsdatensatz eines zufällig ausgewählten Fahrers (Fahrer 4) eingesetzt. Das Labeling erfolgt wie in Kapitel 5.2 beschrieben. Für das Trainieren und Testen werden die oben genannten fünf Signale

mit deren jeweiligen Minimum, Maximum, Mittelwert und Standardabweichung über die ausgewählte Zeit von 2 s verwendet (vgl. Kapitel 5.2.2). Dieser Zeitbereich wird aus den fünf zu präzisierenden Werten und dem letzten Wert vor der Prädiktion abgedeckt. In Abbildung 5.3 sind diese durch die grünen und den roten Datenpunkt dargestellt.

Mit Hilfe der Grid-Search (Rastersuche) Suchmethode zur Hyperparameteroptimierung (vgl. Goodfellow et al. [39]) werden unterschiedliche Random Forests getestet, um den für diese Anwendung am besten geeigneten zu finden. Dafür wird der Datensatz in 80 % Trainingsdaten und 20 % Validierungsdaten geteilt, um anschließend jeden Random Forest mit den Trainingsdaten zu trainieren. Der Schwellwertparameter wird so eingestellt, dass die maximale FPR 1 % beträgt. Die dabei resultierenden RPRs sind in Abbildung 5.10 dargestellt.



**Abbildung 5.10.:** Grid-Search für den am besten geeigneten Random Forest, nach [183]

Abbildung 5.10 zeigt, dass eine Tiefe von zehn mit insgesamt 30 Bäumen die beste RPR ergibt. Diese beträgt im ausgeführten Beispiel 96,9%. Außerdem ist in Abbildung 5.10 zu sehen, dass eine geringe Anzahl an Bäumen oder flache Strukturen zu einer schlechten Modellierung der Fahrerintention führen. Dennoch garantiert eine steigende Anzahl an Bäumen oder eine tiefere

Architektur keine stetig steigenden RPRs. Darüber hinaus steigt mit der Komplexität der Architektur des Random Forests auch der Rechenaufwand zur Bestimmung der Fahrerintention. Aus diesen Gründen soll für alle weiteren Betrachtungen ein Random Forest bestehend aus 30 Bäumen mit einer Tiefe von zehn verwendet werden.

### 5.3.3. STUFE 3: ENTSCHEIDUNG ÜBER DAS ANHALTEN

Die dritte Stufe des Algorithmus zur Fahrerintentionserkennung dient dazu, aus der Intention des Fahrers anzuhalten eine Aussage zu erhalten, ob das Fahrzeug wirklich anhalten wird. Dazu wird die Fahrerintention mit der Bedingung  $v < 7 \text{ kmh}^{-1}$  in einer einfachen Regel UND-verknüpft. Möchte der Fahrer anhalten, wird bei Unterschreiten der Geschwindigkeit von  $7 \text{ kmh}^{-1}$  ein Stopp prädiziert. Als Geschwindigkeitswert wird die in 2 s prädizierte Geschwindigkeit eingesetzt.

Durch diese UND-Verknüpfung im Regelsatz ist die Entscheidung direkt nachzuvollziehen und zu interpretieren, was für die Absicherung datenbasierter Algorithmen hilfreich ist. Zusätzlich verringert diese Regel die Anzahl der FPs, welche in den schwierig zu prädizierenden Übergangsphasen zwischen der Fahrerintention „Weiterfahren“ und „Anhalten“ auftreten können.

## 5.4. TRAINING DES ENTWICKELTEN ALGORITHMUS

Das Training des entwickelten Algorithmus erfolgt wie in Kapitel 2.8 beschrieben in zwei Schritten. Beim Vortrainieren wird ein allgemeiner Datensatz für die Fahrerintentionserkennung verwendet, während beim Nachtrainieren fahrer- bzw. fahrzeugspezifische Daten eingesetzt werden.


Für das Vortrainieren des Algorithmus wird der dafür entwickelte Datensatz zufällig in 80 % Trainings- und 20 % Validierungsdaten aufgeteilt und damit anschließend das RNN sowie der Random Forest trainiert. Die Initialisierung der Gewichte des neuronalen Netzwerks in Stufe 1 erfolgt dabei

zufällig. Jede Stufe bzw. der jeweils zugrundeliegende Machine Learning Algorithmus wird unabhängig von den anderen Stufen optimiert. Die trainierten Modelle des RNNs und Random Forests werden zusammen mit der Regel aus Stufe 3 in einem Prädiktionspfad seriell verschaltet. Im Testpfad zur Überprüfung der Klassifikationsergebnisse mit einem separaten Datensatz werden die gelabelten Daten der Zeitreihenprädiktion direkt mit dem generalisierten Regelsatz der Stufe 2 sowie der Stufe 3 verarbeitet. Durch Gegenüberstellen des Prädiktions- und Testpfads kann der Trainingserfolg und die Testgenauigkeit überprüft werden. Nach Abschluss des Trainings ist der Algorithmus für die Fahrerintentionserkennung auf einen allgemeinen Datensatz bzw. einen durchschnittlichen Fahrer und ein Fahrzeug angepasst.

Der Einfluss der zufälligen Initialisierung des RNNs ist wie in [164] gezeigt sehr gering. Die RPR ändert sich bei konstanter FPR und gleichbleibendem Netzwerk- und Datensatzaufbau weniger als 0,1 %, während die Test-MSE in fünf Trainingsdurchläufen um max. 1,27 % variiert. Dieser geringe Einfluss der Initialisierung kann für weitere Untersuchungen vernachlässigt werden.

In Kapitel 2.4.2 wird der erwartete Verlauf der Lernkurven für Trainings- und Validierungsdaten skizziert, welcher auch beim Training des entwickelten Algorithmus zu beobachten ist (siehe Abbildung 5.11). Die Trainings- und Validierungs-MSEs verlaufen besonders zu Beginn des Trainings sehr ähnlich. Die Tendenz der Trainingskosten ist stetig fallend, während die Kurve der Validierungskosten in der Overfitting Zone abflacht und das globale Minimum von Epoche 65 nicht mehr erreicht. Das Training des Algorithmus wird daher durch ein Early Stopping nach 80 Epochen abgebrochen, nachdem sich die Validierungs-MSE innerhalb von 15 Epochen nicht mehr verbessert (vgl. Kapitel 2.4.2). Das aus Epoche 65 optimal generalisierte Netzwerk wird abgespeichert und in späteren Analysen verwendet.

Das Nachtrainieren erfolgt ähnlich wie das Vortrainieren, wobei die Ausgangssituation ein bereits trainierter Algorithmus ist und nur bestimmte Teile des Netzwerkes und des Random Forests angepasst werden. Der fahrer- bzw. fahrzeugspezifische Trainingsdatensatz wird zufällig in 80 % Trainings- und 20 % Validierungsdaten aufgeteilt. Zusätzlich wird ein Testdatensatz für das finale Evaluieren des Algorithmus eingesetzt, wodurch neben einem Prädiktionspfad auch wieder ein Testpfad besteht.



**Abbildung 5.11.:** Verlauf der Trainings- und Validierungs-MSEs beim Vortrainieren der ersten Stufe, nach [184]

Für das Nachtrainieren des RNNs werden unterschiedliche Transfer Learning Methoden (vgl. Kapitel 2.8) in Tabelle 5.4 gegenübergestellt. Dabei wird die Verbesserung der MSEs nach Stufe 1 mit einem Transfer Learning in einzelnen Schichten gegenüber dem vortrainierten Ergebnis dargestellt. Tabelle 5.4 zeigt, dass die Verbesserung durch die jeweilige Transfer Learning Methode von den verwendeten Daten abhängt. So sind im Durchschnitt für die vier Fahrer das Training der letzten beiden bzw. letzten drei Schichten am besten geeignet, wobei für Fahrer 1 und 4 das Nachtrainieren aller Schichten die größte Verbesserung unter den evaluierten Transfer Learning Methoden aufweist. Zwischen dem Transfer Learning in den letzten beiden bzw. drei Schichten ist kaum ein Unterschied festzustellen. Deshalb soll, unter zusätzlicher Berücksichtigung des Rechenaufwands, für das in dieser Arbeit beschriebene RNN ein Transfer Learning in den letzten beiden Schichten erfolgen. Dem Vergleich der verschiedenen Methoden des Nachtrainierens kann außerdem entnommen werden, dass das Hinzufügen einer neuen Schicht für alle Fahrer, außer für Proband 3,



eine Verschlechterung der MSE bewirkt. Dies kann dadurch begründet werden, dass damit die Netzwerkarchitektur für die Fahrerintentionserkennung gestört wird und zu wenige Daten für das vollständige Anpassen zur Verfügung stehen. Die messbare Verbesserung der MSE beim Nachtrainieren der letzten beiden Schichten im Vergleich mit der letzten Schicht bestätigt, dass das Anpassen der interpretierenden FC Schichten zu einer genaueren Prädiktion beitragen kann. Der geringe Unterschied zwischen dem Nachtrainieren der letzten zwei bzw. drei Schichten zeigt, dass in den LSTM Zellen generell zeitliche Zusammenhänge gelernt werden, während die FC Schichten für deren Interpretation zuständig sind. Die zeitlichen Zusammenhänge bleiben für einzelne Fahrer und Fahrzeuge im Vergleich zu einem generalisierten Datensatz nahezu gleich.

**Tabelle 5.4.:**

Vergleich verschiedener Transfer Learning Methoden und die Verbesserung der MSE durch diese [185]

	<b>MSE nach Transfer Learning in Schicht/-en</b>					
	<b>alle</b>	<b>erste</b>	<b>neue</b>	<b>letzte</b>	<b>letzte 2</b>	<b>letzte 3</b>
	[%]	[%]	[%]	[%]	[%]	[%]
Fahrer 1	-15,10	-12,05	8,92	-14,58	-14,98	-15,00
Fahrer 2	-9,18	-8,62	12,30	-9,40	-9,58	-9,58
Fahrer 3	-18,04	-15,30	-6,72	-19,86	-20,57	-20,47
Fahrer 4	-14,63	-12,45	6,38	-13,66	-13,77	-13,94
∅	-14,24	-12,10	5,22	-14,37	-14,73	-14,74

Auch der Random Forest wird mit Hilfe der fahrer- bzw. fahrzeugspezifischen Daten angepasst. Hierfür wird der generalisierte Entscheidungsbaum zum Labeling der Daten erneut trainiert und damit der Random Forest für die Stufe 2 erstellt. Damit kann einerseits eine fahrer- bzw. fahrzeugspezifische Klassifikation erfolgen, andererseits sind der vor- und nachtrainierte Algorithmus nur noch begrenzt vergleichbar. Dies ist vor allem durch die unterschiedlichen Label zu begründen, welche eine generalisierte bzw. eine angepasste Wahrheit repräsentieren. Das zugrundeliegende richtige Label ist damit abhängig vom Datensatz für jeden Fahrer unterschiedlich.


## 5.5. ERGEBNISSE UND DISKUSSION DER FAHRERINTENTIONSERKENNUNG

Die Ergebnisse der Fahrerintentionserkennung werden in die beiden Trainings-schritte des Vor- und Nachtrainierens unterteilt und getrennt voneinander betrachtet. Alle Ergebnisse basieren auf dem Datensatz für das Vortrainieren, wobei für das Transfer Learning zusätzlich fahrer- bzw. fahrzeugspezifische Datensätze eingesetzt werden. Die Trainings-, Validierungs- und Testdatensätze werden unabhängig voneinander aufgebaut und überschneiden sich nicht, was eine zuverlässige Bewertung des Algorithmus ermöglicht.

### 5.5.1. VORTRAINIERTER ALGORITHMUS

Die vortrainierte Fahrerintentionserkennung erreicht nach 65 Epochen in Stufe 2 eine RPR von 93,5 % und eine FPR von 4,7 %. Nach Stufe 3 erfolgt eine Klassifikation mit einer RPR von 94,0 % und einer FPR von 2,8 % (siehe Abbildung 5.12). Bei diesen Werten handelt es sich um gemessene Punkte der ROC-Kurve, wobei mit einer realistischen Interpolation (vgl. Kapitel 2.3.1) für Stufe 2 bzw. Stufe 3 RPRs von 93,5 % bzw. 94,1 % bei einer FPR von 5 % resultieren. Abbildung 5.12 zeigt eindeutig, dass die Klassifikationsgenauigkeit für Stufe 3 stets höher ausfällt als für Stufe 2. Dies liegt daran, dass Klassifikationsfehler bzw. -unsicherheiten in Stufe 2 vor allem im Übergang zwischen der Intention des Fahrers weiterzufahren bzw. anzuhalten auftreten. Durch die Plausibilisierung in Stufe 3 können die Klassifikationsergebnisse über der Geschwindigkeitsschwelle eindeutig dem Label „Weiterfahren“ zugeordnet werden. Dabei werden unsichere, häufig falsche, Prädiktionen verworfen und nicht als Anhalten klassifiziert. Trotzdem verfehlt der vortrainierte Algorithmus sowohl nach Stufe 2 als auch nach Stufe 3 die geforderte RPR von 95 % bei einer maximalen FPR von 5 % (vgl. Kapitel 5.1.2).

Für die ROC-Kurve der Stufe 3 ist bei einer FPR zwischen 0,4 % und 1,3 % eine geringe Steigung zu erkennen, was v.a. an der geringen Anzahl und ungleichmäßigen Verteilung der Trainingsdaten liegt. Zum Testen des vor-



**Abbildung 5.12.:** ROC-Kurven des vortrainierten Algorithmus, nach [185]

trainierten Algorithmus werden die Testdaten der vier Fahrer verwendet, womit insgesamt ungefähr 4700 Sequenzen zur Verfügung stehen. Viele dieser Fälle können mit sehr hoher Sicherheit dem Label „Fahrzeug hält nicht an“ zugeordnet werden, weshalb auch der Mittelwert der Prädiktion des Random Forest nahe 0 liegt. Viel weniger Sequenzen werden eindeutig einem Anhalten zugeordnet, also ungefähr dem Wert 1 des Random Forest. Der Bereich zwischen diesen Extremwerten ist durch die geringe Anzahl der Testbeispiele nur ungleichmäßig und spärlich belegt. Diese Beobachtung wird durch die Schwelle für das Erkennen eines Anhaltens von  $7\text{ kmh}^{-1}$  zusätzlich verstärkt. Dadurch stehen hinter jedem Punkt der ROC-Kurve nur eine sehr kleine Anzahl von Testbeispielen, wodurch einzelne FNs zu einem Einbruch der RPR führen können.


Die beiden ROC-Kurven aus Abbildung 5.12 zeigen einen stufigen, nicht kontinuierlichen Verlauf, was ebenfalls auf die geringe Anzahl von Testdaten zurückzuführen ist. Sprünge in den Kurven sind v.a. durch die ungleichmäßige Verteilung der Klassifikationsergebnisse der Testbeispiele im Random Forest

zu begründen, wobei potentielle Werte nicht oder nur sehr gering besetzt sind. Die Anzahl von 30 Entscheidungsbäumen im Random Forest spielt keine messbare Rolle, weil das Mitteln der prädizierten Wahrscheinlichkeiten der einzelnen Bäume zu einem kontinuierlichen Ausgabewert führt. Diese Umsetzung erfolgt standardmäßig in der Python-Bibliothek `sklearn`.

Für weitere Auswertungen des vortrainierten Algorithmus nach Stufe 3 werden aus dem aufgebauten Testdatensatz je 30 Anhaltvorgänge an Zebrastreifen und sonstigen Situationen manuell ausgewählt. Diese sonstigen Situationen enthalten u.a. Anhalten an Ampeln, Vorfahrtstraßen oder bei Parkvorgängen. Für die Untersuchung der zeitlichen Abhängigkeit der Prädiktion werden die Sequenzen der Eingangsdaten von 8,2 s vor (vgl. [165]) bis 2 s nach dem Anhalten (vgl. Kapitel 5.1.2) analysiert. Die manuell gelabelten Punkte der Zebrastreifen und sonstigen Ursachen des Anhaltens liegen nachfolgend jeweils bei 0 s. Dieser Punkt wird mit Hilfe des Geschwindigkeitsverlaufs bzw. des Minimalwerts der Geschwindigkeit gelabelt. Für alle durchgeführten Analysen der RPRs und FPRs in zeitlicher Abhängigkeit zum Zebrastreifen wird ein Schwellwert für die Prädiktion von 0,66 verwendet. Dies bedeutet, dass Prädiktionen mit einem Wahrscheinlichkeitswert über 0,66 als Anhalten klassifiziert werden.

Abbildung 5.13 zeigt, dass sich die Klassifikationsgenauigkeit des Anhaltens an Zebrastreifen von sonstigen Situationen unterscheidet. Bis zu einer FPR von 11,8 %, und damit im Bereich der Anforderung an das System der Fahrerintentionserkennung, ist die RPR der sonstigen Anhaltesituationen höher als die an Fußgängerüberwegen, während sich dieses Verhältnis über einer FPR von 11,8 % umkehrt. Der Datensatz für den vortrainierten Algorithmus setzt sich aus zeitlichen Sequenzen um Zebrastreifen zusammen. Deshalb ist zu erwarten, dass die RPRs der Prädiktion in diesen Fällen höher sind als in anderen Situationen. Im Detail setzt sich der Datensatz jedoch aus Teilabschnitten von 60 s langen Sequenzen zusammen, jeweils 30 s vor und nach dem Erkennen des Fußgängerüberwegs (siehe Kapitel 5.2). Aus diesem Grund sind neben dem Anhalten am Zebrastreifen auch sehr viele Anhaltvorgänge vor und nach einem Zebrastreifen im Datensatz enthalten, weshalb das Anhalten in sonstigen Situationen besser vom Datensatz abgedeckt wird und zu höheren RPRs führt. Die ROC-Kurven aus Abbildung 5.13 zeigen deut-

lich schlechtere Klassifikationsgenauigkeiten als die ROC-Kurve des selben Algorithmus in Abbildung 5.12. Dies hängt mit der Auswahl der Testdaten zusammen. Während für die oben beschriebene Evaluation Testdaten aus allen Fahrsituationen verwendet werden, werden hier (Abbildung 5.13) ausschließlich Anhaltefälle betrachtet. Dadurch entfallen fast alle Testbeispiele mit konstanter Geschwindigkeit, stehendem Fahrzeug oder Beschleunigung nach dem Anhalten, wodurch sich die Anzahl der RNs und RPs verringert. Damit steigt gleichzeitig die FPR und die RPR sinkt (vgl. Kapitel 2.3.1).




**Abbildung 5.13.:** ROC-Kurven nach Stufe 3 für Anhalten an Zebrastreifen und sonstige Situationen, nach [184]

Die Abweichung des prädizierten Wahrscheinlichkeitswerts vom dazugehörigen Label für das Anhalten ist ca. 6,6 s vor und 1,4 s nach den Zebrastreifen minimal (vgl. Abbildung 5.14). In Abbildung 5.14 ist außerdem zu erkennen, dass die Abweichung von Prädiktion und Label 0,7 s vor den Zebrastreifen maximal ist. Der zeitliche Verlauf der mittleren Abweichung wird mit einem gleitenden Mittelwert über zehn Datenpunkte bzw. 100 ms geglättet. Trotzdem weist die Abbildung 5.14 ein großes Rauschen und einige Ausreißer auf, was

auf die geringe Anzahl von 30 Testbeispielen zurückzuführen ist. Im Bereich von ca. 5 s bis 2 s vor Zebrastrifen ist die Abweichung von Prädiktion und Label sehr hoch (vgl. Abbildung 5.14). Dies zeigt unter Berücksichtigung des Prädiktionshorizonts von 2 s, dass wenige Sekunden vor dem Anhalten nur eine geringere Genauigkeit erreicht werden kann. Der Prädiktionshorizont von 2 s führt dazu, dass der Algorithmus zu jedem Zeitpunkt eine Vorhersage der Fahrerintention in 2 s durchführt. Damit sind die Prädiktion, aber auch das Label und die tatsächlich eintretende Wirklichkeit um 2 s zueinander verschoben. Label und Prädiktion liegen damit im gleichen Zeitbereich, präzisieren jedoch einen zukünftigen Zustand. In genau diesem Zeitbereich ist auch das Aufstellen des Regelsatzes für das automatisierte Labeln des Datensatzes (vgl. Kapitel 5.2) am schwierigsten, weil nicht eindeutig ist, welche Eingangsdaten eine Anhalteintention widerspiegeln. Es ist deshalb davon auszugehen, dass in diesem zeitlichen Bereich das Labeling am inkonsistentesten erfolgt und deshalb der Algorithmus mit einer geringeren Genauigkeit prädiziert. Die geringe Abweichung bei -1,4 s kann ebenfalls mit Hilfe des Prädiktionshorizont des Algorithmus erklärt werden. In vielen Fällen liegt hier, wie im Bereich vor -5 s, eine konstante Geschwindigkeit vor, welche vom Algorithmus ebenfalls sehr zuverlässig prädiziert werden kann.

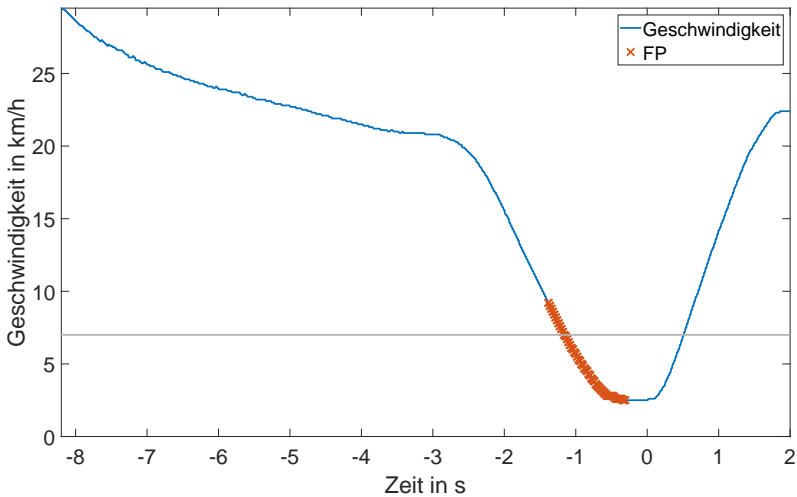
Die größte Abweichung von Prädiktion und Label ca. 0,7 s vor den Zebrastrifen (vgl. Abbildung 5.14) ist auf die Beschleunigung nach dem Anhalten und damit verbundene FPs zurückzuführen. Eine Prädiktion bei 0,7 s vor dem Anhalten bezieht sich mit dem Prädiktionshorizont von 2 s auf einen Zeitpunkt 1,3 s nach dem Anhalten. Zu diesem Zeitpunkt beschleunigen die Fahrer in den Testbeispielen wieder, wodurch der Algorithmus wegen den vorliegenden Eingangsdaten fälschlicherweise eine Anhalteintention prädiziert. Die entstehende Abweichung von Prädiktion und Label bzw. die dafür verantwortlichen FPs können in Abbildung 5.15 eindeutig beobachtet werden. Im Bereich von 1,4 s bis 0,3 s vor dem Anhalten wird in diesem beispielhaft ausgewählten Fall ein Anhalten prädiziert, obwohl am Ende des Prädiktionshorizonts von 2 s der Fahrer das Fahrzeug bereits auf eine Geschwindigkeit von  $8,5 \text{ kmh}^{-1}$  beschleunigt. Die dadurch bzw. systembedingten FPs haben in der Praxis keine Auswirkung auf die Anzeige von Zeichen für Fußgänger an Fußgängerüberwegen, weil das Fahrzeug zu diesem Zeitpunkt tatsächlich



**Abbildung 5.14.:** Mittlere Abweichung der Prädiktion vom Label in zeitlicher Abhängigkeit zum Zebrastreifen, nach [184]

noch steht oder gerade erst losfährt. Ein Losfahren wird erst leicht verspätet, nach einzelnen Zeitschritten in denen der Fahrer beschleunigt, erkannt, wobei auch dies keine Einschränkung für eine Fahrzeug-Fußgänger-Kommunikation birgt. Neben diesen zusammenhängenden FPs beim Beschleunigen nach einem Anhaltvorgang, treten FPs auch als einzelne Falschklassifikationen auf, die mit Hilfe eines Tiefpass-Filters verworfen werden könnten.


Die Analyse der FPRs in zeitlicher Abhängigkeit zum Zebrastreifen zeigt, dass zwischen  $-1,5\text{ s}$  und  $0,7\text{ s}$  eine sehr ungenaue Klassifikation erfolgt (siehe Abbildung 5.16). Dieser Bereich überschneidet sich größtenteils mit dem der hohen Abweichung von Prädiktion und Label (vgl. Abbildung 5.14). Der in Abbildung 5.16 etwas größere Bereich der hohen FPRs kann durch eine große Anzahl von RPRs und deren hohen Genauigkeit ab  $-0,3\text{ s}$  in Abbildung 5.14 ausgeglichen werden. Die Ausreißer, v.a. beim Verlauf der RPR-Kurve, können wieder durch die geringe Anzahl von Testbeispielen begründet werden. Damit zeigt sich für die RPR bis ca.  $2\text{ s}$  vor dem Anhalten eine niedrigere Klassifikationsgenauigkeit als nach diesem Zeitpunkt.



**Abbildung 5.15:** Beispiel für einen Geschwindigkeitsverlauf und auftretende FPs in zeitlicher Abhängigkeit zum Zebrastreifen, nach [184]

Dies deutet unter Berücksichtigung des Prädiktionshorizonts darauf hin, dass der entwickelte Algorithmus v.a. am Zebrastreifen ein sehr genaues Erkennen der Anhalteintention ermöglicht. Die zeitliche Auswertung der RPRs bzw. FPRs und der Abweichung von Prädiktion und Label zeigt jedoch, dass der Algorithmus neben einer sehr guten Fahrerintentionserkennung beim Anhalten eine sehr viel schlechtere Prädiktion des Beschleunigens erlaubt. Nachdem der Algorithmus ein Anfahren initial erkannt hat, ist die Klassifikationsgenauigkeit ab ca. 1 s nach dem Anhalten wieder hoch (vgl. Abbildung 5.14 und Abbildung 5.16). Dies zeigt das Problem auf, dass ein erneutes Beschleunigen nicht kausal ist und dieses deshalb auch nicht frühzeitig vorhergesagt werden kann, was insbesondere auf die verwendete Metrik zurückzuführen ist.





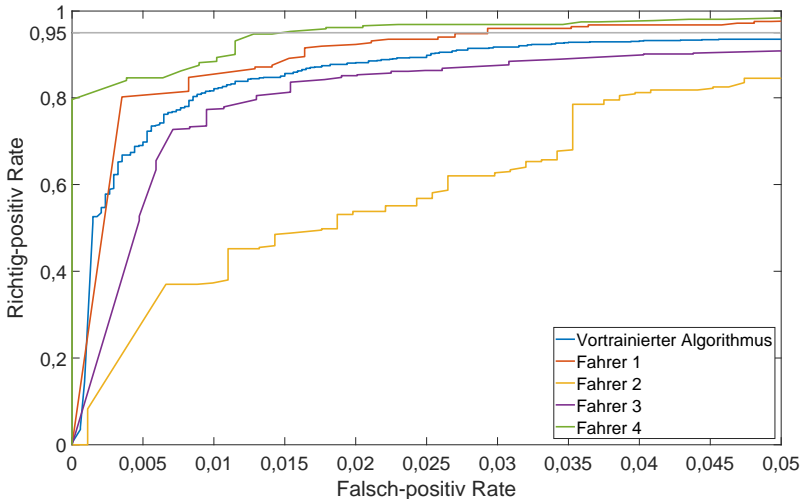
**Abbildung 5.16.:** Mittlere RPR und FPR in zeitlicher Abhängigkeit zum Zebrastreifen, nach [184]

### 5.5.2. NACHTRAINIERTER ALGORITHMUS

Der vortrainierte Algorithmus wird wie in Kapitel 5.4 beschrieben mit einem Transfer Learning auf fahrer- bzw. fahrzeugspezifische Verhaltensweisen angepasst. Die ROC-Kurven nach Stufe 2 und Stufe 3 des Algorithmus sind in Abbildung 5.17 und Abbildung 5.18 dargestellt. Das Anpassen der Stufen 1 und 2 des Algorithmus erfolgt dabei mit Daten von jeweils einem Fahrer und einem Fahrzeug für vier Testpersonen.

Abbildung 5.17 zeigt, dass das Nachtrainieren für Fahrer 4 nach Stufe 2 im gesamten Bereich zu höheren RPRs führt als der vortrainierte Algorithmus. Dies gilt auch für Fahrer 1, wobei die realistische Interpolation der Punkte der ROC-Kurve zwischen einer FPR von 0,1 % und 0,2 % unter dem allgemeinen Modell liegt. Ab einer FPR von 2,9 % verläuft die ROC-Kurve dieses Fahrers mit 96,0 % über der minimal zu erreichenden RPR von 95 %. Die ROC-Kurve des Fahrers 4 überschreitet die vorgegebene RPR mit 95,3 % bei einer FPR von

1,5 %. Die RPRs der Fahrer 2 und 3 liegen im gesamten Bereich deutlich unter der des vortrainierten Algorithmus.

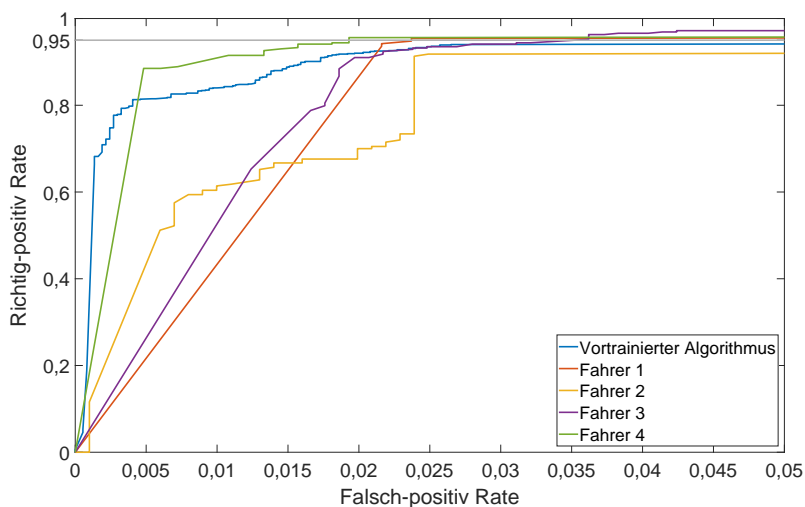


**Abbildung 5.17.:** ROC-Kurven des nachtrainierten Algorithmus nach Stufe 2, angepasst an jeweils einen Fahrer und ein Fahrzeug, nach [185]

Insbesondere die Klassifikationsgenauigkeit von Fahrer 2 liegt über den gesamten Bereich weit unter der des vortrainierten Netzwerks. Die Verschlechterung durch das Anpassen des vortrainierten Algorithmus kann v.a. durch ein ungleichmäßiges Fahrverhalten des Fahrers begründet werden und bestätigt damit eine entsprechende Beobachtung während der Datenaufnahme. Das Verhalten des Fahrers 2 variiert während der Trainingsdatenaufzeichnung auf der Referenzstrecke deutlich. Dadurch versucht der Algorithmus, die beiden ersten Stufen auf stark unterschiedliche Daten anzupassen, was v.a. durch die geringe Datenanzahl nicht möglich ist. Im Gegensatz dazu ist das Fahrverhalten von Fahrer 1 und 4 sehr konstant über die gesamte Referenzstrecke, wodurch auch das Anpassen des Algorithmus zu höheren Klassifikationsgenauigkeiten führt, als mit dem vortrainierten Algorithmus. Wie auch schon in Abbildung 5.12 zu sehen ist, zeigen die Verläufe der ROC-Kurven in Abbil-

dung 5.17 und Abbildung 5.18 einen stufigen, nicht kontinuierlichen Verlauf. Dies kann ebenfalls auf eine geringe Anzahl von ca. 1180 Testdaten pro Fahrer zurückgeführt werden.

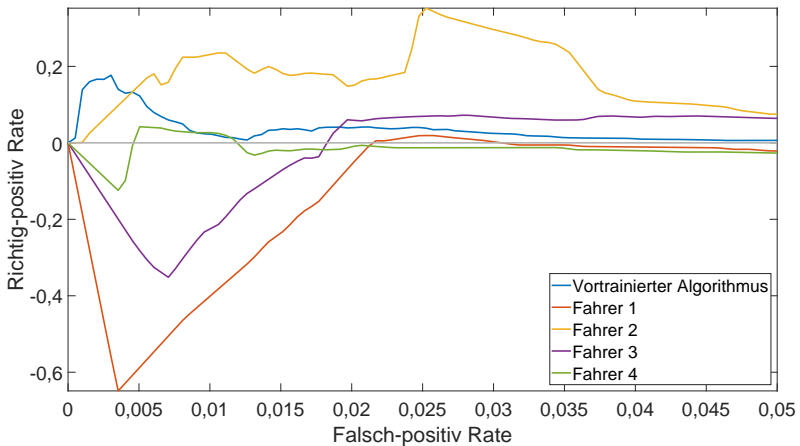
Der grundsätzliche Verlauf der ROC-Kurven für die Fahrer 1 und 4 der Stufe 3 stimmen mit denen der Stufe 2 überein und die RPRs liegen über denen des vortrainierten Algorithmus. Die minimale RPR wird für beide Fahrer mit 95,4 % bzw. 95,6 % bei einer FPR von 2,4 % bzw. 1,9 % überschritten. Die ROC-Kurve des Fahrers 3 verläuft ab einer FPR von ca. 2,8 % über der des vortrainierten Algorithmus und erreicht bei einer FPR von 3,6 % eine RPR von 95,2 %. Auch nach der Plausibilisierung in Stufe 3 liegen die RPRs des an den Fahrer 2 angepassten Algorithmus stets unter der des vortrainierten.



**Abbildung 5.18.:** ROC-Kurven des nachtrainierten Algorithmus nach Stufe 3, angepasst an jeweils einen Fahrer und ein Fahrzeug, nach [185]

Dies zeigt, dass mit einer Ausnahme für Fahrer 2 ein Nachtrainieren und damit verbundenes Anpassen an fahrer- bzw. fahrzeugspezifische Verhaltensweisen zu höheren Klassifikationsgenauigkeiten führen kann. Dies gilt insbesondere für das Erreichen der Anforderungen an das System (vgl. Kapitel 5.1.2), was


nur mit Hilfe des Transfer Learnings möglich ist. Für Fahrer 2 verschlechtert sich die Klassifikationsgenauigkeit des Algorithmus durch das Anpassen an seine Daten. Dies zeigt, dass erwartungsgemäß v.a. der zugrundeliegende Datensatz und ein konstantes Fahrverhalten für den Erfolg des Transfer Learnings ausschlaggebend sind. Für alle ROC-Kurven ist ein stufiger, nicht kontinuierlicher Verlauf zu beobachten, was mit der geringen Anzahl von Testbeispielen begründet werden kann (siehe oben).



**Abbildung 5.19.:** Differenzbild der ROC-Kurven von Stufe 3 und Stufe 2 des nachtrainierten Algorithmus, angepasst an jeweils einen Fahrer und ein Fahrzeug, nach [184]

Das Differenzbild der jeweiligen ROC-Kurven von Stufe 3 und Stufe 2 (siehe Abbildung 5.19) zeigt die Filterwirkung der Geschwindigkeitsschwelle von  $7 \text{ kmh}^{-1}$  in der letzten Stufe. Für den vortrainierten Algorithmus und den an Fahrer 2 angepassten Algorithmus verbessert diese Schwelle die RPRs über den gesamten Bereich. Dies deutet darauf hin, dass durch Anwenden der Geschwindigkeitsschwelle unsicher zu klassifizierende Datenpunkte direkt der Klasse „Weiterfahren“ zugeordnet werden. Für Fahrer 1 und Fahrer 4 zeigen die Differenzkurven bis zu einer FPR von ca. 2,1 % bzw. 0,5 % einen negativen Wert, wobei dies mit der realistischen Interpolation der ROC-Kurven

für die Stufe 3 in diesem Bereich zusammenhängt. Für beide Fahrer fällt die Differenzkurve in Abbildung 5.19 bei höheren FPRs erneut unter den Wert 0. Diese Verschlechterung beeinflusst die Klassifikation kaum, weil der optimale Arbeitspunkt bereits vorher erreicht wird. Abbildung 5.19 stellt für Fahrer 3 ab einer FPR von ca. 1,9% positive Differenzen dar. Dies bedeutet, dass erst ab einer FPR von ca. 1,9% die Stufe 3 zu einer Verbesserung der RPR gegenüber Stufe 2 führt. Wie oben beschrieben erfüllt die ROC-Kurve für Fahrer 3 erst ab einer FPR von ca. 3,6% die Anforderungen an das System, weshalb auch diese Verschlechterung durch die Stufe 3 bis zu einer FPR von ca. 1,9% keinen Einfluss hat. Zusammenfassend erhöht die Stufe 3 damit die Klassifikationsgenauigkeit.

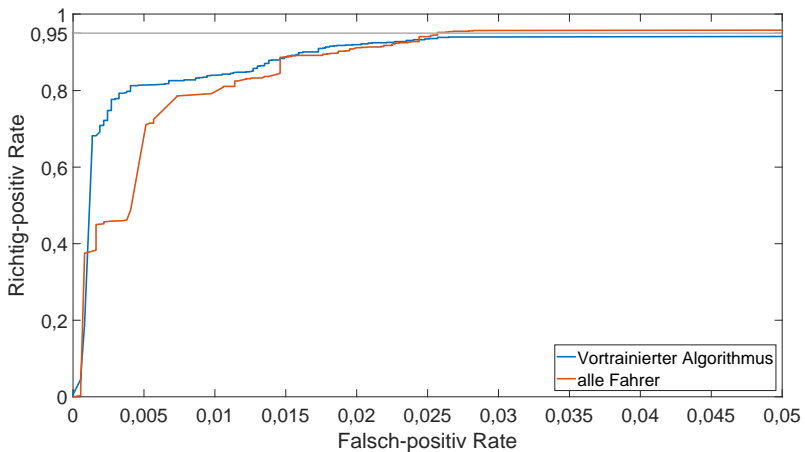


**Abbildung 5.20.:** ROC-Kurven des nachtrainierten Algorithmus nach Stufe 2, angepasst an vier Fahrer und ein Fahrzeug, nach [184]

Zusätzlich zur Anpassung der Stufen 1 und 2 des Algorithmus an jeweils einen Fahrer und ein Fahrzeug, kann der Algorithmus an ein Fahrzeug ohne fahrerspezifische Merkmale angepasst werden. Dafür wird ein Transfer Learning mit den gesamten Trainingsdaten der vier Fahrer durchgeführt und mit den zusammengefassten Testdaten dieser Testpersonen evaluiert. Nach Stufe 2 zeigen der vor- und nachtrainierte Algorithmus einen sehr ähnlichen

Verlauf, wobei bis zu einer FPR von 4,3 % der vortrainierte Algorithmus leicht höhere RPRs aufweist (siehe Abbildung 5.20). Bei der geforderten maximalen FPR von 5 % liegt die RPR des angepassten Algorithmus mit 94,2 % über dem vortrainierten (93,5 %). Die Anforderung an das System wird damit jedoch nicht erreicht.

Nach Stufe 3 des Algorithmus zeigt die ROC-Kurve (siehe Abbildung 5.21) des fahrzeugspezifisch angepassten Klassifikators einen ähnlichen Verlauf wie für Stufe 2. Bis zu einer FPR von 2,4 % liegt die RPR des vortrainierten Algorithmus fast im gesamten Bereich über der des angepassten. Ab einer FPR von 2,6 % erfüllt der nachtrainierte Algorithmus die Anforderungen an das System mit einer RPR von 95,2 %. Zwischen der FPR von 0,2 % und 0,7 % liegt die RPR des nachtrainierten Algorithmus deutlich unter der Vergleichskurve.



**Abbildung 5.21.:** ROC-Kurven des nachtrainierten Algorithmus nach Stufe 3, angepasst an vier Fahrer und ein Fahrzeug, nach [184]

Abhängig vom Arbeitspunkt des Algorithmus kann der an fahrzeugspezifische Daten angepasste Algorithmus den vortrainierten Klassifikator nach Stufe 3 in der Klassifikationsgenauigkeit übertreffen. Die Unterschiede zum vortrainierten Algorithmus sind ab einer FPR von 1 % gering. Die lediglich kleinen Abweichungen der ROC-Kurven der beiden Klassifikatoren nach Stufe

2 erlauben keine eindeutige Aussage darüber, ob eine fahrzeugspezifische Anpassung des Algorithmus möglich ist. Auch nach Stufe 3 ist der Unterschied der Klassifikationsgenauigkeiten zwischen dem vor- und nachtrainierten Algorithmus zu gering, um eine klare deskriptive Tendenz beobachten zu können.

### 5.5.3. WEITERE ERGEBNISSE

Eine Untersuchung der Trainings-, Validierungs- und Test-MSE erfolgt sowohl für das vortrainierte, als auch für die nachtrainierten Netzwerke nach Stufe 1 des Algorithmus. Da die Testdaten während des Trainings für das neuronale Netzwerk unbekannt sind, ist zu erwarten, dass die Test-MSE unter diesen am höchsten ist. Die Validierungs-MSE wird ungefähr genauso hoch bzw. geringfügig niedriger erwartet, da diese zum Abbruch des Trainings nur teilweise in den Trainingsprozess mit einfließt.

Für die Evaluation der MSEs ergeben sich für drei Fahrer Abweichungen von den theoretisch hergeleiteten Größenverhältnissen der Genauigkeitsmaße. Bei dem vortrainierten und den personalisierten Netzwerken für Fahrer 2 sowie für alle Fahrer gemeinsam ist die Trainings-MSE wie erwartet niedriger als die Validierungs-MSE und diese wiederum niedriger als die Test-MSE (vgl. Tabelle 5.5). Dies stimmt mit dem Verlauf der MSE in Abbildung 5.11 und Goodfellow et al. überein [39]. Die Test-MSEs für Fahrer 1 und 3 liegen weit unter der Validierungs-MSE, während für Fahrer 4 die Validierungs-MSE niedriger ist als die Trainings-MSE (vgl. Tabelle 5.5). Diese Abweichung von den erwarteten Größenverhältnissen hängt vermutlich mit der geringen Menge an Validierungs- und Testdaten zusammen. Schon eine geringe Anzahl ungenau oder falsch prädizierter Validierungs- oder Testbeispiele kann hierbei die mittlere MSE messbar beeinflussen. Die theoretischen Größenverhältnisse der verschiedenen MSEs ergeben sich v.a. bei dem vortrainierten Netzwerk und dem auf die Daten aller Fahrer angepasste Netzwerk, bei denen jeweils größere Datenmengen zur Verfügung stehen. Die Verbesserungen der Test-MSE durch ein Transfer Learning in den letzten beiden Schichten der Stufe 1 für die jeweiligen Fahrer (vgl. Tabelle 5.4) stimmen mit den Ergebnissen

in Tabelle 5.5 überein. Die geringste Verbesserung ergibt sich bei Fahrer 2, während Fahrer 3 die größte Verbesserung aufweist. Dadurch resultiert auch für Fahrer 3 die niedrigste Test-MSE der an die jeweiligen Fahrer angepassten Netzwerke und für Fahrer 2 die höchste.

**Tabelle 5.5.:**

Trainings-, Validierungs- und Test-MSE für das vortrainierte und die nachtrainierten Netzwerke, nach [184]

	Trainings-MSE [ $10^{-4}$ ]	Validierungs-MSE [ $10^{-4}$ ]	Test-MSE [ $10^{-4}$ ]
Vortrainiertes Netzwerk	2,65	3,15	3,16
Fahrer 1	4,72	8,02	6,75
Fahrer 2	5,42	5,45	6,93
Fahrer 3	4,11	4,45	4,10
Fahrer 4	3,06	1,66	5,00
alle Fahrer	4,10	4,53	6,63

Die verschiedenen MSEs des vortrainierten Netzwerks liegen in fast allen Fällen unter denen der angepassten Algorithmen (vgl. Tabelle 5.5). Dies steht im Gegensatz zu den Ergebnissen bei der Analyse der ROC-Kurven (siehe oben), kann aber mit einer einfachen Erklärung nachvollzogen werden. Das Transfer Learning der nachtrainierten Algorithmen erfolgt nicht nur in Stufe 1 des Algorithmus, sondern auch in Stufe 2, in welcher die Label bzw. der Entscheidungsbaum und der dazugehörige Random Forest angepasst werden. Deshalb unterscheiden sich die Generierung der Label in Stufe 2 je nach Fahrer bzw. je nachdem, ob ein vortrainierter oder angepasster Algorithmus eingesetzt wird. Dadurch wird das wahre Label subjektiviert und an den jeweiligen Anwendungsfall angepasst, weshalb unterschiedliche MSEs zu konträren Ergebnissen der ROC-Kurven führen können. Dies zeigt darüber hinaus, dass die angepassten Netzwerke in Stufe 1 größere Prädiktionsfehler, aber trotzdem eine sehr hohe Genauigkeit in der Interpretation der Prädiktionen in Stufe 2 aufweisen. Wie genau eine Klassifikation des gesamten Algorithmus ist, hängt also von dem Zusammenspiel der einzelnen Schichten ab. Eine Korrelation der



Test-MSE mit der resultierenden ROC-Kurve ist für die ähnlichen Datensätze der einzelnen Fahrer nicht gegeben.

Die einzeln auftretenden FPs (siehe oben) weisen darauf hin, dass mit Hilfe einer Tiefpass gefilterten Klassifikation, z.B. gleitender Mittelwert über drei Zeitschritte, die FPR des Algorithmus leicht verringert werden kann. Ein Nachteil eines Tiefpass Filters ist die zeitliche Verzögerung der Prädiktion, die je nach Filterlänge unterschiedlich ausgeprägt sein kann. Weiter treten FPs häufig beim Losfahren des Fahrzeugs auf (vgl. Abbildung 5.15 und Abbildung 5.16). Die Genauigkeit der Klassifikation eines Anhaltens ist demnach voraussichtlich höher als die kumulierte RPR und FPR für das Anhalten und Losfahren des Fahrzeugs. Im Gegensatz dazu beziehen die mittleren Werte jedoch auch Fahrten bei konstanter und hoher Geschwindigkeit mit ein, welche das Ergebnis durch viele RPs und RNs verbessern.

Jede ROC-Kurve entsteht durch Variation eines Schwellwerts, mit welchem entschieden werden kann, ob eine Prädiktionswahrscheinlichkeit als Anhalten klassifiziert wird oder nicht. Jeder Punkt der ROC-Kurve kann also einem bestimmten Schwellwert zugeordnet werden. Der Schwellwert soll im vorliegenden Fall so gewählt werden, dass die minimale RPR von 95 % und maximale FPR von 5 % eingehalten werden. Zusätzlich soll die FPR so klein wie möglich sein, da diese Falschprädiktionen ein Sicherheitsrisiko für alle Verkehrsteilnehmer darstellen können. Für das vortrainierte Netzwerk wird daher ein Schwellwert von 0,77 gewählt.

Im Vergleich mit den Ergebnissen anderer Arbeiten übertrifft der hier beschriebene Algorithmus deren Klassifikationsgenauigkeit deutlich. Wie in Kapitel 3.3 beschrieben, wird von Tran et al. [124] und Zhu et al. [129] eine Accuracy von 90 % bzw. 80,39 % und von Garcia Ortiz et al. [130] mit einem Prädiktionshorizont von 2 s eine RPR/FPR von ca. 65%/10 % erreicht. Bereits der vortrainierten Algorithmus liegt bei gleichem Prädiktionshorizont mit RPR/FPR von 94,0%/2,8 % deutlich höher. Die Accuracy ist in diesem Beispiel ca. 96,6 % und damit um 6,6 % bzw. 16,2 % höher als in den oben genannten Veröffentlichungen.

## 5.6. UNTERSUCHUNGSKRITIK AN DER FAHRERINTENTIONSERKENNUNG

Die nachfolgende Untersuchungskritik bezieht sich auf die verwendeten Daten, das Labeling der Daten und die Vollständigkeit der Evaluation.

Für die aufgebauten Datensätze sind vor allem die Diversität und Menge der Daten wichtige Kritikpunkte. Der Datensatz für das Vortrainieren des Algorithmus ist ausschließlich aus Fahrdaten der Breitenerprobung von Audi aufgebaut. Alle Fahrer der AUDI AG durchlaufen spezielle Fahrertrainings und sind nur begrenzt mit ungeschulten Verkehrsteilnehmern zu vergleichen. Nach manueller Überprüfung zufällig ausgewählter Zeitsequenzen kann jedoch davon ausgegangen werden, dass die Ergebnisse mit Kundendatensätzen ähnlich ausfallen würden.

Des Weiteren sind die Referenzstrecken für das Transfer Learning auf den Großraum Ingolstadt begrenzt. Dadurch sind die Ergebnisse dieser Arbeit nur eingeschränkt für andere Kulturen und Verkehrsräume gültig. Bei der geringen Anzahl von vier untersuchten Testpersonen sind eindeutig messbare Abweichungen zwischen den Fahrern zu erkennen. Lediglich größere Stichproben von Fahrern können ein zuverlässiges Ergebnis darüber liefern, ob das Anpassen des Algorithmus die Klassifikationsgenauigkeit erhöht. V.a. bei der Personalisierung auf je einen Fahrer und ein Fahrzeug zeigen sich eindeutige, deskriptive Tendenzen, dass ein Nachtrainieren die Prädiktion verbessert. Dies kann jedoch für nur vier Fahrer nicht ausreichend statistisch bestätigt werden. Außerdem umfassen v.a. die Daten für das Testen des nachtrainierten Algorithmus nur eine geringe Anzahl von Zeitsequenzen, wodurch die Interpretation der Ergebnisse erschwert wird (bspw. stufige ROC-Kurven). Zum Training des Algorithmus der Fahrerintentionserkennung an Fußgängerüberwegen wird eine geringe Anzahl von Situationen am Zebrastreifen eingesetzt. Ähnlich viele Anhaltefälle aus weiteren Gründen werden für das Training verwendet, wodurch die Anpassung an Fußgängerüberwege nur eingeschränkt erfolgt.

Das Labeling der Daten bzw. der Aufbau des Regelsatzes mit 39 manuell erstellten Regeln erfolgt nach einer subjektiven Einschätzung von Experten

(vgl. Kapitel 5.2.1). Dadurch ist auch die zugrundeliegende Wahrheit, ob ein Fahrer anhalten möchte bzw. das Fahrzeug anhalten wird subjektiv und generalisiert. Zur Objektivierung dieses Lablings könnte eine Expertenbeurteilung jedes Beispiels oder eine Bewertung der Beispielsequenzen mittels mehrerer Testpersonen erfolgen.

Die in dieser Arbeit angestellten Untersuchungen können nicht als vollständig abgeschlossen betrachtet werden und geben daher lediglich einen vorläufigen Forschungsstand wieder. So werden bspw. nicht alle in der Literatur bekannten Aktivierungsfunktionen oder im Fahrzeug verfügbaren Signale untersucht. Außerdem könnte z.B. die Grid-Search für den am besten geeigneten Random-Forest feiner durchgeführt und für weitere Tiefen oder Anzahl von Bäumen erweitert werden. In diesem Fall sind keine oder nur kleine Verbesserungen zu erwarten. Trotzdem könnte durch eine umfassendere, möglichst vollständige Evaluation der hier vorgestellte Algorithmus wahrscheinlich verbessert werden. Mit dieser Arbeit soll daher kein Anspruch auf Vollständigkeit erhoben werden.

Durch separates Anpassen jeder Stufe des Algorithmus kann, wie in Kapitel 5.4 und Kapitel 5.5.1 gezeigt, ein funktionsfähiger Algorithmus entwickelt werden. In Kapitel 5.5 wird gezeigt, dass die Test-MSEs nach Stufe 1 nicht mit den Ergebnissen der ROC-Kurven nach Stufe 2 bzw. 3 korrelieren. Statt jede Stufe des Netzwerks einzeln zu optimieren, könnte eine Anpassung der Stufe 1 unter Berücksichtigung von Stufe 2 und 3 zu einer höheren Klassifikationsgenauigkeit führen.

Wegen einer starken Datensatzabhängigkeit der Ergebnisse (vgl. Kapitel 5.4) und den kleinen Testdatensätzen ergeben sich in den oben dargestellten Ergebnissen stufige Verläufe der ROC-Kurven oder inkonsistente Zahlenwerte. Eine Möglichkeit, dem entgegenzuwirken, ist der Einsatz einer Kreuzvalidierung (siehe Kapitel 2.3.2). Mit Hilfe der unterschiedlichen Aufteilungen von Test- und Trainingsdatensätzen durch die Cross-Validation kann ein gemittelttes Ergebnis für die verschiedenen Genauigkeitsmaße erzeugt werden. Damit wird die Verwendung eines größeren Testdatensatzes abgelöst. Trotzdem wird in dieser Arbeit auf die Tests des entwickelten Algorithmus mittels Kreuzvalidierung verzichtet, damit eine eindeutige Trennung zwischen Trainings-

und Testdatensatz gewährleistet werden kann. Durch die zeitliche Überlapung von Datensätzen (vgl. Abbildung 5.3) kann diese Trennung nur schwer erreicht werden. Mit der gewählten und in dieser Arbeit vorgestellten Implementierung ist die Trennung zwischen Trainings- und Testdaten garantiert.

Zusätzlich können für eine Untersuchungskritik zwei systematische Fehler identifiziert werden. Kapitel 5.5.1 zeigt, dass beim Erkennen des Anhaltens kaum FPs auftreten, beim erneuten Beschleunigen des Fahrzeugs je nach Fahrverhalten jedoch stets FPs zu beobachten sind. Dies wird in den Evaluationen der Prädiktion der Fahrerintention nicht berücksichtigt und könnte demnach zu niedrigeren FPRs führen. Die beim Beschleunigen auftretenden FPs könnten bspw. durch eine Plausibilisierung mit der Gaspedalbetätigung reduziert werden. Generell ist jedoch anzumerken, dass ein Erkennen der Beschleunigung mit den vorliegenden Daten nicht kausal ist und demnach nicht erkannt werden kann. In der Praxis bzw. bei der Anwendung der Fahrerintentionserkennung zur Fahrzeug-Fußgänger-Kommunikation ist jedoch keine wahrnehmbare Einschränkung gegeben. Außerdem führt das Personalisieren der Entscheidungsbäume für das Labeling der Daten in Stufe 2 zu subjektiv angepassten Wahrheiten für jeden Testfahrer. Dies ist generell richtig, da jeder Fahrer auch ein anderes Maß für das Labeling ansetzen würde, führt jedoch dazu, dass die Ergebnisse nur noch begrenzt vergleichbar sind.

In Kapitel 5.1.2 wird eine Anforderung an das System definiert, bei der über einen Prädiktionshorizont von 2 s eine RPR von 95 % bei einer FPR von 5 % erreicht werden soll. Die personalisierten Netzwerke von Fahrer 1, 3, 4 und für alle Fahrer gemeinsam erfüllen diese Anforderungen nach Stufe 3, trotzdem kann der Algorithmus nicht uneingeschränkt im Straßenverkehr eingesetzt werden. Obwohl durch ein Entprellen bzw. Filtern der Klassifikation und ausschließliche Prädiktion eines Anhaltens die Anzahl von FPs voraussichtlich verringert werden kann, stellt die vorliegende FPR weiterhin ein Risiko für andere Verkehrsteilnehmer dar. Dieses Risiko sollte unbedingt vermieden werden, weshalb die angestrebte Anforderung nach Omerbegovic [189] ( $RPR \geq 95\%$  und  $FPR \leq 5\%$ , siehe Kapitel 5.1.2) für den Serieneinsatz der hier vorgestellten Anwendung als unzureichend sicher eingeschätzt wird.



---

## KAPITEL 6

# ZUSAMMENFASSUNG UND AUSBLICK

In diesem Kapitel werden die Ergebnisse aus den Untersuchungen zur Fahrzeug-Fußgänger-Kommunikation und Fahrerintentionserkennung an Fußgängerüberwegen zusammengefasst. Darüber hinaus werden mögliche Umsetzungen in Fahrzeugen aufgezeigt und jeweils ein Ausblick für weitere Evaluationen gegeben. Zum Schluss werden beide Komponenten in ein gesamtheitliches Konzept überführt. Durch die Fahrerintentionserkennung ist es möglich, bereits beim „manuellen Fahren“ standardisierte Symbole bzw. eindeutige Zeichen darzustellen und damit zusätzlich einen großen Teil der Bevölkerung mit der Kommunikation automatisierter Fahrzeuge vertraut zu machen. Das „manuelle Fahren“ wird dabei mit den Stufen 0 bis 2 des automatisierten Fahrens definiert, in denen der menschliche Anteil an der Fahraufgabe überwiegt. Der Fahrer muss das System mindestens dauerhaft überwachen [9].

### 6.1. ZUSAMMENFASSUNG

Bereits heute nimmt eine Kommunikation, also der Austausch von Nachrichten über einen bestimmten Kanal, im Straßenverkehr eine entscheidende Rolle ein und wird v.a. zum Vermeiden und Minimieren von Gefahren oder Unklarheiten eingesetzt. Häufig sind davon Situationen betroffen, bei denen sich Fahrzeuge und Fußgänger den Verkehrsraum teilen, z.B. beim Überqueren eines Fußgängerüberwegs oder in Bereichen mit niedriger Fahrzeuggeschwindigkeit. Daneben ist für den bevorstehenden Mischverkehr von automatisierten Fahrzeugen und herkömmlichen Verkehrsteilnehmern Vertrauen in die


---

neuartige Technologie unbedingt notwendig und dies erfordert eine Fahrzeug-Fußgänger-Kommunikation. Das Visualisieren der Intention, Wahrnehmung oder des Zustandes automatisierter Fahrzeuge kann bspw. mittels Lichtzeichen und hierfür entwickelten Leuchtenarrays sowie Displays erfolgen. In Kapitel 3 werden v.a. Botschaften zur Interaktion mit Fußgängern an Fußgängerüberwegen als wichtig hervorgehoben. So werden Zeichen und Farben zur Anzeige eines automatisierten Fahrmodus, des Vorfahrt-gewährens für Fußgänger und Erkennen eines Fußgängers untersucht. Darüber hinaus konnte in einer Voruntersuchung bereits ein intuitiv verständliches Symbol zur Darstellung einer Warnung gefunden werden, bei welcher der Fußgänger aufgefordert wird die Straße nicht zu überqueren.

Die durchgeführte Voruntersuchung zur Intuitivität von Zeichen und Dynamiken zeigt, dass 29 von 30 statischen und dynamischen Zeichen nicht intuitiv verständlich sind. Lediglich eines der betrachteten Symbole wird von den Probanden im Erstkontakt erkannt (Symbol 27, Abbildung 6.1). In einer Zuordnung von vorgegebenen Antworten und Zeichen werden elf aus 30 Symbolen richtig gedeutet und als verständlich bzw. aussagekräftig bewertet. Diese Ergebnisse werden in einer Onlinestudie mit 709 Probanden bestätigt. Die Teilnehmer sollen sich dabei in die Lage eines Fußgängers an einem Fußgängerüberweg versetzen, den sie überqueren möchten während sich ein Fahrzeug annähert. In diesem Zusammenhang werden Zeichen zur Darstellung eines automatisierten Fahrmodus, Vorfahrt gewähren für Fußgänger und Erkennen des Fußgängers ausgewählt. Insgesamt werden neun Symbole untersucht, von denen zwei mittels offener Antworten im Erstkontakt richtig gedeutet werden. Diese beiden Symbole für das Vorfahrt gewähren für Fußgänger sind bereits aus dem Straßenverkehr bekannt. In der Zuordnung der Symbole und vorgegebenen Antworten werden drei Zeichen zuverlässig und mit einer signifikant höheren ER als die mindestens geforderte ER von 67 % erkannt (AD3, C2 und D1, Abbildung 6.1). In der anschließenden Untersuchung von sechs Farben zur Unterstützung der Verständlichkeit der Symbole wird lediglich Grün besser bewertet als Weiß. Dies ist besonders deutlich für die Darstellung der Symbole für ein Gewähren der Vorfahrt.

Die Gegenüberstellung der Erkennungsraten und Konfidenzbewertungen der offenen und vorgegebenen Antworten zeigt eindeutig, dass bereits bekannte

Symbole stets als verständlich und aussagekräftig bewertet werden, während unbekannte Symbole v.a. aus einer vorgegebenen Auswahl von Bedeutungen sicher erkannt werden. Dies deutet darauf hin, dass Symbole nach einem Lernprozess in relevanten Situationen des Straßenverkehrs zuverlässig und richtig erkannt werden können. Die Voruntersuchung legt nahe, dass auch die Erkennungszeiten durch einen Lernprozess erheblich reduziert werden können.



**Abbildung 6.1.:** Ausgewählte Symbole für ein Konzept zur Fahrzeug-Fußgänger-Kommunikation, nach [104][163]

Für ein vorgeschlagenes Kommunikationskonzept automatisierter Fahrzeuge an Fußgängerüberwegen werden die vier in Abbildung 6.1 dargestellten Symbole aufgrund ihrer hohen Verständlichkeit ausgewählt. Für die Farbe dieser wird entgegen den Ergebnissen aus der Onlinestudie Weiß statt Grün ausgewählt, um die Verwechslungsgefahr mit Ampelanlagen zu vermeiden und farbfeldsichtige Verkehrsteilnehmer nicht zu benachteiligen. Eine mögliche Umsetzung des Konzepts wäre das dauerhafte Anzeigen von Symbol AD3 im automatisierten Fahrmodus, um das Vertrauen in die Technologie zu erhöhen. In der Nähe eines Fußgängerüberwegs, der mittels Navigations-, Strecken- und Kameradaten ermittelt werden kann, wird im Falle des Vorfahrtgewährens für Fußgänger das Symbol C2 angezeigt. Falls das Fahrzeug nicht anhalten wird, weil es bspw. keinen Fußgänger erkannt hat, kann es das Symbol 27 am Display darstellen. Um eine kritische Handlungsempfehlung auszuschließen, kann anstelle von C2 auch D1 angezeigt werden, wenn ein Fußgänger erkannt wird. Damit zeigt das Fahrzeug nicht Symbol C2 und damit, dass dem Fußgänger Vorfahrt gewährt wird, sondern mittels D1 lediglich, dass das Fahrzeug den Fußgänger erkannt hat. Dies ist mit einem Blickkontakt zu vergleichen, welcher lediglich bedeutet, dass ein Fußgänger erkannt wird und nicht wie in einer Geste, dass dieser die Straße überqueren kann.



Um die nochmals zusammengefasste Fahrzeug-Fußgänger-Kommunikation auch bereits im „manuellen Fahren“ umzusetzen, wird in dieser Arbeit ein Algorithmus zur Fahrerintentionserkennung vorgestellt. Damit können die Intention des Fahrers an Fußgängerüberwegen anzuhalten bestimmt werden und dementsprechend die passenden Symbole angezeigt werden.

Zur Analyse von zeitlichen Abfolgen und Signalsequenzen werden in der Literatur hauptsächlich rekurrente neuronale Netzwerke eingesetzt. Diese unterscheiden sich von Feedforward Neural Networks durch eine Rückführung bzw. Hidden State und können beispielsweise zur Prädiktion oder Analyse von Zeitreihen verwendet werden. Im Vergleich mit konventionellen Algorithmen des maschinellen Lernens setzten sich in den vergangenen Jahren vor allem LSTMs, spezielle RNNs, durch. Die Absicherung datenbasierter Algorithmen, v.a. für sicherheitskritische Anwendungen, ist eine wichtige Herausforderung und kann mittels verschiedener Ansätze erfolgen (vgl. Kapitel 3.4).

Zur Prädiktion einer Fahrerintentionserkennung an Fußgängerüberwegen wird in Kapitel 5 ein mehrstufiger Algorithmus aufgebaut und sowohl mit durchschnittlichen und als auch mit fahrer- bzw. fahrzeugspezifischen Datensätzen trainiert. Der implementierte Machine Learning Algorithmus ist zur Absicherung und besseren Interpretierbarkeit in drei Stufen aufgeteilt. Zur genaueren Evaluation des entwickelten Algorithmus werden Klassifikationen an Zebrastreifen und sonstigen Situationen, in denen das Fahrzeug anhält, gegenübergestellt. Als Anforderung an das System werden im Hinblick auf die Zielanwendung einer Fahrzeug-Fußgänger-Kommunikation an Fußgängerüberwegen eine Richtig-positiv Rate von mindestens 95 % und eine Falsch-positiv Rate von höchstens 5 % gefordert.

Der in dieser Arbeit entwickelte Algorithmus zur Fahrerintentionserkennung an Fußgängerüberwegen besteht aus drei Stufen. In der ersten Stufe ist ein RNN bestehend aus vier LSTM-Schichten mit jeweils 64 Zellen und zwei Fully-connected Layers implementiert, welches zur Prädiktion von fünf Signalsequenzen dient. Diese zeitabhängigen Signale werden in der zweiten Stufe mit Hilfe eines Random Forest bestehend aus 30 Bäumen mit einer Tiefe von zehn interpretiert. Dies ist eine binäre Klassifikation, ob der Fahrer anhalten möchte oder nicht, aus welcher eine Wahrscheinlichkeit der Fahrerintention

resultiert. In der letzten Stufe des Algorithmus wird eine Geschwindigkeitsschwelle von  $7\text{ kmh}^{-1}$  zur Plausibilisierung verwendet, ob das Fahrzeug im Prädiktionshorizont von  $2\text{ s}$  auch wirklich anhalten wird.

Für das Vortrainieren des Algorithmus wird ein allgemeiner Datensatz bestehend aus  $782.840$  Zeitreihen in der Nähe von  $7114$  Fußgängerüberwegen aufgebaut. Zusätzlich wird der Algorithmus an die fahrer- bzw. fahrzeugspezifischen Fahreigenschaften von vier Testpersonen und einem Fahrzeug angepasst. Dazu werden zwei Referenzstrecken im Raum Ingolstadt definiert, die zur Aufnahme jeweils eines Trainings- und eines Testdatensatzes dienen. Die Referenzstrecke zur personalisierten Aufzeichnung von Trainingsdaten ist insgesamt  $36,3\text{ km}$  lang und beinhaltet sechs Zebrastrifen, neun Fußgängerüberquerungshilfen und  $79$  weitere Verkehrssituationen, in denen das Fahrzeug anhalten könnte. Der fahrer- bzw. fahrzeugspezifische Testdatensatz umfasst eine Strecke von  $3,3\text{ km}$  und  $18$  potentielle Situationen, Fußgängern die Vorfahrt zu gewähren.

Sowohl der Datensatz für das Vortrainieren als auch die Datensätze für das Nachtrainieren des Algorithmus bestehen aus jeweils  $22$  Features bzw. Signalen. Diese Bussignale beinhalten bspw. Geschwindigkeit, Bremsdruck, eine Verkehrszeichenerkennung oder Informationen aus der Objekterkennung der Fahrzeugkamera (vgl. Kapitel 5.2.2). Mit diesen  $22$ , je  $3,5\text{ s}$  langen Zeitreihen werden fünf Signale über einen Prädiktionshorizont von  $2\text{ s}$  prädiziert. Diese dienen als Eingang für die Stufe 2 des Algorithmus (siehe oben) und beinhalten die Features Geschwindigkeit, Bremsdruck, Lenkradwinkel, Längs- und Querbeschleunigung.

Der vortrainierte Algorithmus zur Fahrerintentionserkennung verfehlt die Anforderungen an das System für eine minimale RPR von  $95\%$  und eine maximale FPR von  $5\%$ . Nach einer realistischen Interpolation der ROC-Kurve (vgl. Kapitel 2.3.1) wird für die maximale FPR in Stufe 3 eine RPR von  $94,1\%$  gemessen. Die Klassifikationsgenauigkeit bzw. RPR nach Stufe 3 ist vor allem für niedrige FPRs bis  $0,5\%$  um bis zu  $18,6\%$  höher als das nicht plausibilisierte Ergebnis nach Stufe 2.

In einer zusätzlichen Evaluation des vortrainierten Algorithmus mit ausgewählten Daten wird die Klassifikationsgenauigkeit an Zebrastrifen und sonstigen Anhaltesituationen gegenübergestellt. Bis zu einer FPR von ca.  $11\%$  liegen

die RPRs der ROC-Kurve an Zebrastreifen unter der in sonstigen Anhaltessituationen. Dies zeigt, dass der Algorithmus besonders für das Prädizieren eines Anhaltens des Fahrzeugs in sonstigen Situationen geeignet ist, z.B. an Ampelanlagen oder Kreisverkehren. Weiter zeigt die Untersuchung an Zebrastreifen, dass ein Anhalten sehr sicher erkannt werden kann, die Klassifikation bei erneutem Beschleunigen nach dem Fußgängerüberweg jedoch häufig zu FPs führt. Dies wird durch die Evaluation der Abweichung von prädizierter Wahrscheinlichkeit für ein Anhalten und dem jeweiligen Label bestätigt. Das Erkennen, wann der Fahrer losfahren möchte, ist nicht kausal und kann folglich nicht prädiziert werden, in der Praxis ergeben sich dadurch jedoch keine Einschränkungen. Zwar findet, bedingt durch den Prädiktionshorizont von 2 s und dem nicht kausalen Ereignis der Beschleunigung eine Fehlprädiktion statt, doch würde das Fahrzeug lediglich ein Symbol für das Vorfahrt-gewähren anzeigen, solange es noch steht. Sobald das Fahrzeug anfängt erneut zu beschleunigen, erkennt der implementierte Algorithmus, dass der Fahrer nicht anhalten möchte und deaktiviert das Symbol des Vorfahrt-gewährens. Neben zusammenhängenden FPs beim Beschleunigen nach dem Fußgängerüberweg tritt diese Art der Falschklassifikation meistens einzeln auf und kann deshalb herausgefiltert werden. Dadurch entsteht keine gefährliche Situation für andere Verkehrsteilnehmer durch eine widersprüchliche Anzeige zur eigentlichen Intention des Fahrers. Mit dem Einsatz eines Tiefpassfilters ist jedoch je nach Filterlänge eine zeitliche Verzögerung von 10 ms bis ca. 500 ms verbunden. Dabei ist die Länge und Art des Filters für die damit verbundene Verzögerung ausschlaggebend. Demnach sind dieser Argumentation folgend weder die einzeln noch in Gruppen auftretenden FPs ein Hindernis für den Einsatz des entwickelten Algorithmus im Fahrzeug. Dennoch sollten diese Einschätzungen, z.B. in breit angelegten Probandenstudien, überprüft werden, um auch in Zukunft eine maximale Verkehrssicherheit garantieren zu können. Die Sicherheit im Straßenverkehr ist stets in allen Situationen zu gewährleisten, weil besonders in Fällen einer FP-Klassifikation schwache Verkehrsteilnehmer den potentiell größten Schaden davon tragen würden.

Um den Algorithmus an die fahrer- bzw. fahrzeugspezifischen Daten anzupassen wird ein Transfer Learning eingesetzt. Dazu werden die letzten beiden Schichten des neuronalen Netzes aus Stufe 1 mit den jeweiligen Fahrerdaten an

die fahrer- und fahrzeugspezifischen Eigenschaften angepasst. Auch in Stufe 2 des Algorithmus wird sowohl der Entscheidungsbaum für das Labeling der Daten, als auch der Random Forest für die Klassifikation der Fahrerintention personalisiert.

Die fahrer- bzw. fahrzeugspezifischen Algorithmen verbessern die Klassifikationsgenauigkeit für drei der vier Testpersonen, sodass die Anforderungen an das System (vgl. Kapitel 5.1.2) eingehalten werden können. Vor allem Fahrer 1 und 4 erfüllen die Anforderungen an das System und erreichen in den gewählten Arbeitspunkten um 2,3 % und 3,7 % höhere Erkennungsraten als der vortrainierte Algorithmus. Das beste Ergebnis liegt für Fahrer 4 mit einer RPR von 95,6 % und einer FPR von 1,9 % vor. Die ROC-Kurve für Fahrer 2 zeigt eindeutig, dass der Algorithmus nicht für alle Testpersonen erfolgreich angepasst werden kann und dies von den zur Verfügung stehenden Daten abhängt.

Ein Personalisieren des Algorithmus an fahrzeugspezifische Eigenschaften wird durch das Transfer Learning mit allen Trainingsdatensätzen der vier Fahrer umgesetzt. Die ROC-Kurve dieses angepassten Netzwerks übersteigt die Genauigkeit des vortrainierten Algorithmus erst ab einer FPR von 2,6 %. Zwar kann damit eine RPR von 95,2 % erreicht werden, jedoch ist keine klare deskriptive Tendenz zu erkennen, dass mit der Anpassung an fahrzeugspezifische Merkmale die Klassifikationsgenauigkeit verbessert werden kann.

## 6.2. AUSBLICK

In diesem Kapitel werden Forschungsgegenstände für zukünftige Untersuchungen und die Weiterentwicklung des vorgestellten Algorithmus aufgezeigt. Außerdem wird eine mögliche Umsetzung einer kombinierten Anwendung der Fahrerintentionserkennung und der Fahrzeug-Fußgänger-Kommunikation beschrieben.

### 6.2.1. ZUKÜNFTIGE FORSCHUNGSGEGENSTÄNDE

Weitere Untersuchungen sind v.a. im Rahmen von Realfahrstudien anzusetzen, um Limitierungen der bisherigen Untersuchungen zu überwinden. Die prinzipielle Umsetzbarkeit einer Fahrzeug-Fußgänger-Kommunikation konnte in den beiden Studien nachgewiesen werden, doch sind Abweichungen in realen Verkehrssituationen möglich. So können v.a. Ablenkung durch andere Verkehrsteilnehmer, Werbung oder sonstige Distraktoren und die Notwendigkeit, schnell Entscheidungen zu treffen, die Verständlichkeit von Zeichen negativ beeinflussen. Es gilt weiter zu untersuchen, ob andere Verkehrsteilnehmer durch die Anzeige von bestimmten Zeichen abgelenkt werden. Außerdem sind im Straßenverkehr häufig Situationen anzutreffen, in welchen mehr als ein Fahrzeug und ein Fußgänger beteiligt sind und miteinander kommunizieren. Hierfür sind weitere Untersuchungen anzustellen, um neben einer Kommunikation des Fahrzeugs mit anderen Fahrern auch die Kommunikation mit mehreren Fußgängern zu erforschen. Besondere Anforderungen werden dabei an das direkte Adressieren einzelner Verkehrsteilnehmer gestellt.

Für dieses direkte Ansprechen eines Verkehrsteilnehmers muss eine lichttechnische Auslegung und Untersuchung von Signalgebern erfolgen. Damit soll die Wirkung gerichteter Lichtquellen in Verbindung mit Symboldarstellungen im Straßenverkehr untersucht werden, um eine missverständliche oder ungewollte Kommunikation auszuschließen. Außerdem ist es zum aktuellen Zeitpunkt weitestgehend unklar, welche Leuchtdichte, Kontrast, Abstrahlcharakteristik und Größe die Displays und Leuchtenarrays vorweisen sollen. Deshalb ist weiterhin auch offen, welche Technologie sich zur Kommunikation im Straßenverkehr am besten eignet. Denkbar wären bspw. LCD- oder OLED-Displays, OLED- bzw. LED-Leuchtenarrays oder nachts auch Projektionssysteme wie Laserscanner- oder Mikrospiegel-Scheinwerfer.

Außerdem sollen zusätzliche Studien zur Akzeptanz automatisierter Fahrzeuge mit und ohne Kennzeichnung des automatisierten Fahrmodus erfolgen. Die Notwendigkeit für diese Anzeigen wird in Kapitel 3.2.1 aufgrund von Hypothesen oder Wizard-of-Oz Ansätzen hergeleitet. Daraus wird geschlossen, dass eine Fahrzeug-Fußgänger-Kommunikation notwendig ist, damit diese schwachen Verkehrsteilnehmern ein Sicherheitsempfinden zurückerlangen

und ein Vertrauen in die neue Technologie entwickeln. Wizard-of-Oz Ansätze, also das Tarnen eines konventionellen Fahrzeugs als ein automatisiertes Fahrzeug, sind notwendig, da zum aktuellen Zeitpunkt automatisierte Fahrzeuge nur sehr eingeschränkt verfügbar sind und deshalb lediglich wenige Studien mit automatisierten Fahrzeugen durchgeführt werden. Aus diesem Grund ist es weitgehend unklar, wie sich Verkehrsteilnehmer in Anwesenheit von wirklich automatisiert fahrenden Fahrzeugen verhalten.

Als letzter Punkt für eine Kommunikation mit anderen Verkehrsteilnehmern soll auf den Mangel von Untersuchungen zu einer Fahrzeug-Kommunikation hingewiesen werden, welche nicht an Fußgänger adressiert ist. So könnten Fahrzeuge bspw. vor Gefahren im Verkehr warnen, z.B. auf ein nahes Stauende, Pannenfahrzeuge oder Glättesituationen hinweisen. Damit kann in unterschiedlichen Situationen bereits heute die Verkehrssicherheit erhöht und das Vertrauen in neue Fahrzeugtechnologien verstärkt werden. Außerdem könnten Park- und Übergabesituationen automatisierter Fahrzeuge mittels visueller Kommunikation unterstützt werden. So wäre für den Fahrer eines Fahrzeugs und für andere Verkehrsteilnehmer stets ersichtlich, in welchem Zustand sich das Fahrzeug befindet, z.B. Fahrzeugdefekt oder automatisierter Fahrmodus, und welche weiteren Schritte, z.B. Verschließen des Fahrzeugs, für ein Aktivieren des automatisierten Fahrsystems, notwendig sind.

Die in dieser Arbeit vorgestellte Fahrerintentionserkennung kann für verschiedene Anwendungen in Fahrzeugen eingesetzt werden. Diese reichen vom Erkennen der Anhalteintention auf Autobahnen oder Bundesstraßen für eine Warnung anderer Verkehrsteilnehmer, über verbesserte Start-Stopp Systeme und einer prädiktiven Rekuperation bis hin zur Kommunikation mit Fußgängern an Zebrastreifen. Zur Fahrzeugauslieferung könnte der vortrainierte Algorithmus eine Basisfunktionalität erfüllen und für einen durchschnittlichen Fahrer das Anhalten vorhersagen. Dieser Algorithmus könnte bereits mit Hilfe von weiteren Trainingsdaten an den jeweiligen Fahrzeugtyp angepasst sein oder sich erst nach Auslieferung an den Kunden auf das Fahrzeug und den jeweiligen Fahrer personalisieren. Das zugrundeliegende Transfer Learning kann auch als Ergänzung zum Erkennen und Speichern von Fahrprofilen unterschiedlicher Fahrer eingesetzt werden, um so stets bestmöglich dessen Intention zu präzisieren.

Bis zur serientauglichen Implementierung sind jedoch noch weitere Entwicklungsstufen notwendig. So sollen die in dieser Arbeit durchgeführten Evaluationen, insbesondere das Transfer Learning für einzelne Fahrer, weiter getestet werden. Hierfür könnten sowohl weitere Fahrer als auch Fahrzeuge eingesetzt werden oder längere Referenzstrecken für Trainings- und Testdaten aufgezeichnet werden. Außerdem wird empfohlen, weitere Referenzstrecken in den gewünschten Einsatzgebieten zu definieren und mit diesen den Algorithmus zu verbessern. Zuletzt wäre es für eine serientaugliche Umsetzung erforderlich, das Labeling der Daten nicht ausschließlich mit dem hier verwendeten Regelsatz durchzuführen, sondern zusätzlich durch unabhängiges Labeln diverser Testpersonen zu validieren.

Gegenstand zukünftiger Untersuchungen ist der Einsatz von Convolutional Neural Networks bzw. Temporal Convolutional Neural Networks, welche nach Salehinejad et al. eine genauere Prädiktion von Zeitreihen ermöglichen [72]. Diese wurden bereits durch Höß [182] sowie Schleyer [183] untersucht und weisen eine geringfügig niedrigere MSE als die verwendeten RNN-Architekturen auf. Wie in Kapitel 5.5.3 beschrieben, führt eine niedrigere MSE nicht direkt zu höheren RPRs oder niedrigeren FPRs. So zeigt Höß [182], dass die beiden untersuchten Arten der neuronalen Netze vergleichbare Klassifikationsergebnisse aufweisen. Eine weitere Möglichkeit der Fahrerintentionserkennung wird von Ellouze unter Anwendung von Kameradaten beschrieben, welche die Verkehrssituation aufzeichnen [196]. Dabei werden Sequenzen von Kamerabildern direkt als Eingangsdaten eines neuronalen Netzes verwendet. Diese Möglichkeit einer direkten Nutzung von Kamerabildern sollte weiter untersucht werden.

Neben zusammenhängenden Blöcken von FPs beim Losfahren, treten sicherheitskritische Falsch-Positiv Klassifikationen für das Anhalten einzeln auf und könnten mit Hilfe eines Tiefpass-Filters eliminiert werden (vgl. Kapitel 5.5.1). Deshalb sollte für weitere Untersuchungen ein Entprellen der Prädiktion erfolgen. Dies kann bspw. mit einfachen Tiefpass-Filtern, wie gleitenden Mittelwerten, umgesetzt werden, um mit geringem Aufwand die FPR zu reduzieren.

Außerdem wird in [142] darauf hingewiesen, dass Transfer Learning nicht immer den gewünschten Erfolg beim Wissenstransfer eines Bereichs auf einen

anderen aufweist. Somit könnte dieses Verfahren die funktionale Sicherheit negativ beeinflussen und sollte daher stets mit weiteren Tests abgesichert werden [142]. Ein Verlust an Sicherheit darf zu keinem Zeitpunkt stattfinden, weshalb sichergestellt sein muss, dass die Richtig-positiv Rate und Falsch-positiv Rate auf dem gleichen, sehr hohen Niveau bleiben wie vor dem Transfer Learning.

Neben den in diesem Kapitel dargestellten Anwendungsfällen können weitere Use-Cases definiert werden. Die Netzwerkarchitektur der Fahrerintentionserkennung könnte u.a. auf das Prädizieren einer Lenkbewegung angepasst werden. Damit könnte bspw. bestimmt werden, welche Ausfahrt der Fahrer in einem Kreisverkehr verwenden möchte oder ob er einen Fahrstreifenwechsel auf Bundesstraßen oder -autobahnen durchführen wird. Diese Informationen könnten zum automatischen Aktivieren bzw. Deaktivieren des Fahrtrichtungsanzeigers verwendet werden [128].

Darüber hinaus ist die Anwendung dieser Informationen in vernetzten Fahrfunktionen möglich. Das Ergebnis der Fahrerintentionserkennung könnte beispielsweise mit Hilfe eines beliebigen Funkstandards an andere Verkehrsteilnehmer übermittelt werden, damit diese darauf entsprechend reagieren können. Diese Reaktion könnte bspw. einen größeren Abstand zum vorausfahrenden Fahrzeug oder komfortableres Bremsen darstellen. Dadurch könnte eine Strukturierung und Ordnung des Straßenverkehrs ähnlich wie im Flugverkehr erfolgen. Auch die Entwicklung eines vernetzten Start-Stopps könnte durch den Austausch zwischen den Fahrzeugen umgesetzt werden. Wissen andere Fahrzeuge um die Intention des Fahrers, könnten diese bspw. das Antriebssystem frühzeitig starten, um die Dauer zur Fahrbereitschaft zu reduzieren oder den Motor länger deaktiviert lassen, um noch länger Energie zu sparen.

### **6.2.2. ANWENDUNG EINER FAHRERINTENTIONSERKENNUNG ZUR FAHRZEUG-FUSSGÄNGER-KOMMUNIKATION**

Wie bereits in Kapitel 3.2.1 beschrieben, ist eine Fahrzeug-Fußgänger-Kommunikation v.a. zwischen automatisierten Fahrzeugen und Fußgängern



notwendig, jedoch kommunizieren auch Fahrer „manueller Fahrzeuge“ regelmäßig mit anderen Verkehrsteilnehmern. Insbesondere Fußgänger sind auf eine Kommunikation mit dem Fahrer angewiesen, um sich sicher zu fühlen und Vertrauen aufzubauen. In der Kommunikation zwischen Fahrer und Fußgänger im „manuellen“ Verkehr ist es von besonderem Nachteil, dass die verwendeten Zeichen keine eindeutige Nachricht übermitteln, nicht immer gesehen werden können und deren Deutungen inter- bzw. intrapersonell stark variieren können (vgl. Kapitel 3.1). Deshalb wäre auch im heutigen Straßenverkehr bereits eine standardisierte und verständliche Kommunikation hilfreich, die zur optimalen Sichtbarkeit vor allem bei Nacht mittels Fahrzeugleuchten erfolgen kann. Diese Fahrzeug-Fußgänger-Kommunikation kann die heutige Fahrer-Fußgänger-Interaktion ergänzen oder teilweise sogar ersetzen.

Die in dieser Arbeit untersuchten Zeichen einer Fahrzeug-Fußgänger-Kommunikation automatisierter Fahrzeuge weisen eine geringe Intuitivität auf und deren Bedeutungen müssen erst von anderen Verkehrsteilnehmern gelernt werden (vgl. Kapitel 6.1). Diese Erkenntnisse können aus den beiden vorgestellten Untersuchungen (vgl. Kapitel 4.2 und Kapitel 4.3) geschlossen und durch verschiedene andere Arbeiten bestätigt werden (vgl. Kapitel 4.2.2 und Kapitel 4.3.3). Der notwendige Lernvorgang kann bereits beim „manuellen Fahren“ erfolgen, wobei weiterhin die von Fußgängern und anderen Verkehrsteilnehmern erwartete und bekannte Kommunikation mit dem Fahrer besteht. So können in einer Übergangszeit zum automatisierten Fahren bereits im heutigen Straßenverkehr die noch unbekannt, neuen Signale der Fahrzeuge angezeigt werden, während der Fahrer in gewohnter Art und Weise kommuniziert. Dabei lernen Fußgänger die Bedeutung einzelner Zeichen und verknüpfen sie in einem mentalen Modell mit häufig auftretenden Situationen. Durch diese gleichzeitige Anzeige der neuen Zeichen und der bereits bekannten Kommunikation des Fahrers wird die Fahrzeug-Fußgänger-Kommunikation für automatisierte sowie für „manuelle Fahrzeuge“ fortlaufend verständlicher.

Für die Umsetzung der Fahrzeug-Fußgänger-Kommunikation in „manuell“ gesteuerten Fahrzeugen sind verschiedene Ansätze möglich. Zwar wäre auch das manuelle Aktivieren der Fahrzeugleuchten und damit der Anzeige der Zeichen möglich, doch ist das automatische Starten der Kommunikation für den

Fahrer wesentlich komfortabler und sicherer. Damit kann auch ein regelmäßiges Anzeigen der Zeichen sichergestellt werden. Für das automatische Starten der Kommunikation ist eine Fahrerintentionserkennung notwendig, welche bspw. erkennt, wann ein Fahrer anhalten möchte. In Verbindung mit zusätzlichen Informationen zum Situationsverständnis aus Navigations-, Mobilfunk- oder Kamerasystemen können zu jedem Zeitpunkt sinnvolle Zeichen einer Fahrzeug-Fußgänger-Kommunikation angezeigt werden. Ein mögliches Konzept ist, in der Nähe von Fußgängerüberwegen das Symbol 27 darzustellen und bei präzidierter Anhalteintention wahlweise auf Symbol C2 oder D1 zu wechseln (siehe Abbildung 6.1). Mit Hilfe der Information, dass sich das Fahrzeug in der Nähe eines Fußgängerüberwegs befindet, kann ein unnötiges und unpassendes Anzeigen der Symbole vermieden werden, z.B. wenn der Fahrer am Straßenrand halten oder parken möchte. Des Weiteren könnte mittels einer Fußgängerintentionserkennung die Anzeige der Symbole noch situationsspezifischer eingesetzt werden (vgl. Schneemann et al. [111]). Automatisierte Fahrzeuge können zum Unterschied von „manuellen Fahrzeugen“ zu jedem anderen Zeitpunkt das Zeichen AD3 darstellen. Mit einer derartigen Umsetzung könnte die bekannte Fahrer-Fußgänger-Kommunikation fahrerunabhängig ergänzt werden und zusätzlich auch bei schlechten Sichtverhältnissen sicher erfolgen. Gleichzeitig wird die Fahrzeug-Fußgänger-Kommunikation in Vorbereitung auf das automatisierte Fahren von beteiligten Verkehrsteilnehmern erlernt. Um die vom Fahrzeug ausgehenden Gefahren für die Fußgänger weiter zu minimieren wird über die beschriebene Umsetzungsmöglichkeit hinaus empfohlen, bereits bekannte Assistenzsysteme, wie z.B. Manöverassistenten, PreCrash- oder Notbremsassistentensysteme, weiterhin einzusetzen und auch in Zukunft weiterzuentwickeln.

Wie in Kapitel 6.1 beschrieben, erfolgt die Fahrerintentionserkennung nicht zu jedem Zeitpunkt korrekt, was v.a. bei Falsch-Positiv Klassifikationen zu erheblichen Sicherheitsrisiken für Fußgänger führen kann. Dieses Unfallpotential liegt zwar sogar mit der am besten erreichten FPR des Fahrers 4 bei 1,9 % und damit innerhalb der Anforderungen an das System (vgl. Kapitel 5.1.2), jedoch ist diese FPR für eine sichere Anwendung im Straßenverkehr auf dem ersten Blick immer noch deutlich zu hoch. Wie in Kapitel 5.5.1 beschrieben, treten die meisten FP's beim erneuten Beschleunigen nach dem Anhalten an Fußgänger-

überwogen auf, welche jedoch in der Praxis keine negativen Auswirkungen auf die Sicherheit der Fußgänger haben.

Zusätzlich können dem Fahrer im Innenraum die vom Fahrzeug gesammelten Informationen dargestellt werden. Diese beinhalten die erkannte Intention, kreuzende Trajektorien mit anderen Verkehrsteilnehmern oder Position anderer Verkehrsteilnehmer, die potentiell mit dem Fahrzeug bzw. Fahrer interagieren. Die Anzeige kann über ein allgemeines Fahrerinformationssystem, Hinweise im Infotainmentsystem oder dynamische, segmentierte Lichtleisten im Innenraum erfolgen. Um das Risiko einer Falschanzeige der Fahrzeug-Fußgänger-Kommunikation zu minimieren, kann anstelle einer direkten Aktivierung dem Fahrer die Möglichkeit gegeben werden, zusätzlich die Kommunikation freizugeben. Eine solche Eingabeaufforderung kann über ein Infotainmentsystem erfolgen und eine Bestätigung durch Spracheingabe oder Tastendruck erfordern.

Zusammengefasst kann mit der hier vorgestellten Arbeit ein System zur Fahrzeug-Fußgänger-Interaktion sowohl für das automatisierte, als auch für das „manuelle Fahren“ umgesetzt werden. Die symbolbasierte Kommunikation könnte in beiden Fällen sehr ähnlich gestaltet werden, jedoch ist für das „manuelle Fahren“ eine Fahrerintentionserkennung mit dem hier eingeführten Algorithmus notwendig, während beim automatisierten Fahren bereits das nächste Manöver des Fahrzeugs feststeht. Dieser Algorithmus bietet trotz verbleibender Falschprädiktionen von Anhalteintentionen eine für die Praxis sehr gute Einsatzmöglichkeit mit nur geringen Einschränkungen.

---

# LITERATURVERZEICHNIS

- [1] O. Fersen, *Ein Jahrhundert Automobiltechnik: Personenwagen: Ohne Strom geht nichts*, 1. Aufl. Berlin: Springer Berlin, 2014.
- [2] A. Rasouli, I. Kotseruba, und J. K. Tsotsos, "Agreeing to Cross: How Drivers and Pedestrians Communicate," 2017. [Online]. Abgerufen von: <https://arxiv.org/abs/1702.03555> [Zugriff am: 16.02.2018]
- [3] K. Merten, *Informelle Zeichengebung im Straßenverkehr: Bericht zum Forschungsprojekt 7521 der Bundesanstalt für Straßenwesen Bereich Unfallforschung*. Köln: Bundesanstalt für Straßenwesen Bereich Unfallforschung, 1981, Bd. 53.
- [4] R. Risser, *Kommunikation und Kultur des Straßenverkehrs*, 1. Aufl. Wien, Österreich: Literas-Universitäts-Verlag, 1988.
- [5] A. Z. Krahnstöver, "Licht führt!? Konzeption und Evaluation von Fahrmanöverunterstützung durch lichtbasierte Fahrerassistenzsysteme," Dissertation, Technische Universität Braunschweig, Braunschweig, 2016.
- [6] National Highway Traffic Safety Administration and U.S. Department of Transportation, *Traffic Safety Facts: Pedestrians: 2016 Data*, Washington, DC, USA, 2018.
- [7] IIHS, "Fatality Facts 2018: Pedestrians," 2019. [Online]. Abgerufen von: <https://www.iihs.org/topics/fatality-statistics/detail/pedestrians#when-they-died> [Zugriff am: 09.01.2020]
- [8] Statistisches Bundesamt, "Verkehr: Verkehrsunfälle 2018," 2019. [Online]. Abgerufen von: <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Verkehrsunfaelle/> [Zugriff am: 27.02.2020]
- [9] Bundesministerium für Verkehr und digitale Infrastruktur, Ed., *Ethik-Kommission: Automatisiertes und vernetztes Fahren: Bericht*, 2017.
- [10] D. Rothenbücher, J. Li, D. Sirkin, B. Mok, und W. Ju, "Ghost driver: A field study investigating the interaction between pedestrians and
-

- driverless vehicles,” In *25th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*, IEEE, Ed. New York, NY, USA: IEEE, 2016, S. 795–802.
- [11] A. Stuckert, T. Singer, und T. Q. Khanh, “Analysis and classification of road user behavior patterns in megacities and suggestions for additional light signals for automated vehicles in future mixed traffic scenarios,” In *Proceedings of the 13th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2019, S. 629–638.
- [12] F. Schneemann und I. Gohl, “Analyzing driver-pedestrian interaction at crosswalks: A contribution to autonomous driving in urban environments,” In *IEEE Intelligent Vehicles Symposium (IV)*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2016, S. 38–43.
- [13] C. Schiller, “Untersuchung über spektrale Kontrastempfindlichkeitsfunktionen des menschlichen Auges im mesopischen Bereich und ihre Einflussparameter,” Dissertation, Technische Universität Darmstadt, Darmstadt, 2015.
- [14] H. Godthelp, M. de Goede, J. Hogema, R. van der Horst, M. Martens, und P. Rasker, Ed., *Human Factors in Traffic Management: State-of-the-Art Background Document*. Delft, Niederlande: TrafficQuest - Centre for Expertise on Traffic Management, 2012.
- [15] S. Hunscha, “Kommunikations- und Interaktionsmodelle,” Thesis, Universität Bielefeld, Bielefeld, 2003.
- [16] C. E. Shannon, “A Mathematical Theory of Communication,” In *Bell Labs Technical Journal*, R. W. King, Ed., New York, NY, USA, 1948, Bd. 27, S. 379–423.
- [17] K. Mahadevan, S. Somanath, und E. Sharlin, “Communicating Awareness and Intent in Autonomous Vehicle-Pedestrian Interaction,” Research Report, University of Calgary, Calgary, Kanada, 2017.
- [18] C. Ackermann, M. Beggiato, S. Schubert, und J. F. Krems, “An experimental study to investigate design and assessment criteria: What is

- important for communication between pedestrians and automated vehicles?" In *Applied Ergonomics*, P. Dempsey, Ed. Amsterdam, Niederlande: ELSEVIER, 2019, S. 272–282.
- [19] I. Othersen, S. Cramer, und C. Salomon, "HMI for external communication - Kann die Fahrzeugbewegung als Kommunikationskanal zwischen einem Fahrzeug und einem Fußgänger dienen?" In *10. VDI-Tagung Mensch-Maschine-Mobilität*, VDI Wissensforum GmbH, Ed. Braunschweig: VDI Verlag GmbH, 2019, S. 145–154.
- [20] R. Klädtke, S. Hauptmann, und G. Böhm, "Lichttechnik zur Kommunikation beim autonomen Fahren," *ATZ - Automobiltechnische Zeitschrift*, Bd. 120, Nr. 2, S. 30–35, 2018.
- [21] C. Tijus, J. Barcenilla, B. Cambon de Lavalette, und J.-G. Meunier, "The design, understanding and usage of pictograms," In *Written documents in the workplace*, ser. Studies in writing, D. Alamargot, Ed. Amsterdam, Niederlande: ELSEVIER, 2007, S. 17–31.
- [22] C. Mohs, J. Hurtienne, D. Scholz, und M. Rötting, "Intuitivität: definierbar, beeinflussbar, überprüfbar," In *VDI-Berichte*, VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik, Ed. VDI-Verlag, 2006, S. 215–224.
- [23] T. J. Kline und G. A. Beitel, "Assessment of Push/Pull Door Signs: A Laboratory and Field Study," In *Human Factors*. Thousand Oaks, CA, USA: SAGE journals, 1994, S. 684–699.
- [24] R. Dewar, "Criteria for the design and evaluation of traffic sign symbols," In *Transportation Research Record*. Transportation Research Board, 1988, Bd. 21, S. 79–80.
- [25] G.-D. Kim und N. Kwak, "Study on requirements of exterior display for V2X communication according to realizing functions," In *Proceedings of the 13th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2019, S. 611–617.
- [26] H.-C. Lee, *Introduction to color imaging science*. Cambridge, England: Cambridge Univ. Press, 2009.
- [27] International Organisation for Standardization, "ISO 2575: Road vehicles - Symbols for controls, indicators and tell-tales," 01.07.2010.

- [28] L. Fridman, B. Mehler, L. Xia, Y. Yang, L. Y. Facusse, und B. Reimer, "To Walk or Not to Walk: Crowdsourced Assessment of External Vehicle-to-Pedestrian Displays," 2017. [Online]. Abgerufen von: <https://arxiv.org/abs/1707.02698> [Zugriff am: 06.03.2018]
- [29] M. Budanow, C. Jebas, T. Hausmann, und C. Neumann, "Front Lighting System - Future Communication with the Driver," In *VISION 2016, SIA - French Society of Automotive Engineers*, Ed., Paris, Frankreich, 2016.
- [30] T. Lagström und V. M. Lundgren, "Autonomous vehicles' interaction with pedestrians: An investigation of pedestrian-driver communication and development of a vehicle external interface," Master Thesis, Chalmers University of Technology, Gothenborg, Sweden, 2015.
- [31] "J3134: Surface Vehicle Recommended Practice - Automated Driving System (ADS) Marker Lamp(s)," 2019.
- [32] International Organisation for Standardization, "ISO 23049: Road Vehicles - Ergonomic aspects of external visual communication from automated vehicles to other road users," 2018.
- [33] UNECE, "Regulation No. 48: Addendum 47, Revision 12: Installation of lighting and light-signalling devices," Genf, Schweiz, 2014.
- [34] —, "Regulation No. 6: Addendum 5, Revision 6: Direction indicators," Genf, Schweiz, 2014.
- [35] J. Reschke, S. Berlitz, M. Hamm, und W. Huhn, "Communication: Key Capability for the Acceptance of Automated Vehicles," In *7th International Forum on Automotive Lighting*, Shanghai, China, 2019, S. 27–32.
- [36] SAE International, "J3016: Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles," 2016.
- [37] E. Alpaydin, *Introduction to machine learning*, 2. aufl., ser. Adaptive computation and machine learning. Cambridge, MA, USA: MIT Press, 2010.
- [38] T. M. Mitchell, *Machine learning*, ser. McGraw-Hill series in computer science. New York, NY, USA: McGraw-Hill, 1997.

- [39] I. Goodfellow, Y. Bengio, und A. Courville, *Deep Learning*. Cambridge, Massachusetts and London, England: MIT Press, 2016.
- [40] C. M. Bishop, *Pattern Recognition and Machine Learning*, 8. aufl., ser. Information science and statistics. New York, NY, USA: Springer, 2009.
- [41] D. H. Wolpert und W. G. Macready, "No free lunch theorems for optimization," In *IEEE Transactions on Evolutionary Computation*, IEEE Computational Intelligence Society, Ed., 1997, Bd. 1, S. 67–82.
- [42] M. Kubat, *An Introduction to Machine Learning*, 2. aufl. Cham, Schweiz: Springer, 2017.
- [43] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters*, Bd. 27, Nr. 8, S. 861–874, 2006.
- [44] D. Chicco, "Ten quick tips for machine learning in computational biology," In *BioData Mining*, J. Moore und M. D. Ritchie, Ed. Springer Nature, 2017, Bd. 10, S. 35–52.
- [45] G. James, D. Witten, T. Hastie, und R. Tibshirani, *An introduction to statistical learning: With applications in R*, 8. aufl., ser. Springer texts in statistics. New York and Heidelberg and Dordrecht and London: Springer, 2017.
- [46] M. Kuhn und K. Johnson, *Applied predictive modeling*, 5. aufl. New York, NY, USA: Springer, 2016.
- [47] S. Norena, "Python Model Tuning Methods Using Cross Validation and Grid Search," 19.05.2018. [Online]. Abgerufen von: <https://medium.com/@sebastiannorena/some-model-tuning-methods-bfef3e6544f0> [Zugriff am: 13.08.2019]
- [48] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection," In *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence*, C. S. Mellish, Ed. San Mateo, CA, USA: Morgan Kaufmann, 1995, S. 1137–1145.
- [49] A. Luckow, M. Cook, N. Ashcraft, E. Weill, E. Djerekarov, und B. Vorster, "Deep Learning in the Automotive Industry: Applications and Tools," *2016 IEEE International Conference on Big Data*, S. 3759–3768, 2016.



- [50] I. N. D. Silva, D. H. Spatti, R. Andrade Flauzino, L. H. B. Liboni, und S. F. d. Reis Alves, *Artificial neural networks: A practical course*. Cham, Schweiz: Springer, 2017.
- [51] B. Oancea und S. C. Ciucu, "TIME SERIES FORECASTING USING NEURAL NETWORKS," 2014. [Online]. Abgerufen von: <https://arxiv.org/abs/1401.1333> [Zugriff am: 21.05.2019]
- [52] J. Schmidhuber, "Deep Learning in Neural Networks: An Overview," 2015. [Online]. Abgerufen von: <https://arxiv.org/abs/1404.7828> [Zugriff am: 14.08.2019]
- [53] A. Krizhevsky, I. Sutskever, und G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," In *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems*, Lake Tahoe, NV, USA, 2012, S. 1097–1105.
- [54] B. Rohrer, "What can neural networks learn?" 2019. [Online]. Abgerufen von: [https://brohrer.github.io/what\\_nns\\_learn.html](https://brohrer.github.io/what_nns_learn.html) [Zugriff am: 25.01.2019]
- [55] B. Neyshabur, Y. Wu, R. Salakhutdinov, und N. Srebro, "Path-Normalized Optimization of Recurrent Neural Networks with ReLU Activations," 2016. [Online]. Abgerufen von: <https://arxiv.org/abs/1605.07154> [Zugriff am: 29.08.2019]
- [56] X. Glorot, A. Bordes, und Y. Bengio, "Deep Sparse Rectifier Neural Networks," In *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, ser. Proceedings of Machine Learning Research, G. Gordon, D. Dunson, und M. Dudík, Ed., Fort Lauderdale, FL, USA, 2011, S. 315–323.
- [57] W. Ertel, *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung*, 4. aufl., ser. Computational Intelligence. Wiesbaden: Springer Vieweg, 2016.
- [58] M. Anthony und P. L. Bartlett, *Neural network learning: Theoretical foundations*. Cambridge, England: Cambridge Univ. Press, 2009.
- [59] J. Patterson und A. Gibson, *Deep learning: A practitioner's approach*, 1. aufl. Sebastopol, CA, USA: O'Reilly Media, 2017.

- [60] D. P. Kingma und J. L. Ba, "Adam: A Method for Stochastic Optimization," 2014. [Online]. Abgerufen von: <https://arxiv.org/abs/1412.6980> [Zugriff am: 15.10.2019]
- [61] P. M. Radiuk, "Impact of Training Set Batch Size on the Performance of Convolutional Neural Networks for Diverse Datasets," In *Information Technology and Management Science*, Riga Technical University, Ed. Berlin: De Gruyter, 2017, Bd. 20, S. 20–24.
- [62] Tensorflow, "TensorFlow Core r1.14: tf.losses.log\_loss." [Online]. Abgerufen von: [https://www.tensorflow.org/versions/r1.14/api\\_docs/python/tf/losses/log\\_loss](https://www.tensorflow.org/versions/r1.14/api_docs/python/tf/losses/log_loss) [Zugriff am: 01.10.2019]
- [63] —, "Implementation of Loss operations for use in neural networks: r1.14," 2016. [Online]. Abgerufen von: [https://github.com/tensorflow/tensorflow/blob/r1.14/tensorflow/python/ops/losses/losses\\_impl.py#L443-L496](https://github.com/tensorflow/tensorflow/blob/r1.14/tensorflow/python/ops/losses/losses_impl.py#L443-L496) [Zugriff am: 01.10.2019]
- [64] C. C. Aggarwal, *Neural Networks and Deep Learning: A Textbook*. Cham, Schweiz: Springer International Publishing, 2018.
- [65] J. Sola und J. Sevilla, "Importance of input data normalization for the application of neural networks to complex industrial problems," In *IEEE Transactions on Nuclear Science*, IEEE, Ed., Oak Ridge, TN, USA, 1997, Bd. 44, S. 1464–1468.
- [66] S.Thangasamy und L.Latha, "Efficient approach to Normalization of Multimodal Biometric Scores," In *International Journal of Computer Applications*, A. Ahmed, Ed. Foundation of Computer Science, 2011, Bd. 10, S. 57–64.
- [67] S. Prösl, "Deep Learning zur Erkennung der Fahrerintention an Fußgängerüberwegen für ein Lichtassistenzsystem," Master Thesis, Hochschule Kempten, Kempten, 27.09.2018.
- [68] Y. Bengio, P. Simard, und P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," In *IEEE Transactions on Neural Networks*, IEEE, Ed. IEEE, 1994, Bd. 5, S. 157–166.

- [69] J. Hochreiter, "Untersuchungen zu dynamischen neuronalen Netzen," Diplomarbeit, Technische Universität München, München, 1991.
- [70] F. Gers, "Long Short-Term Memory in Recurrent Neural Networks," Dissertation, École polytechnique fédérale de Lausanne, Lausanne, Schweiz, 2001.
- [71] S. Hochreiter und J. Schmidhuber, "Long Short-Term Memory," In *Neural Computation*, Massachusetts Institute of Technology, Ed. Boston, MA, USA: MIT Press, 1997, Bd. 8, S. 1735–1780.
- [72] H. Salehinejad, S. Sankar, J. Barfett, E. Colak, und S. Valaee, "Recent Advances in Recurrent Neural Networks," 2017. [Online]. Abgerufen von: <https://arxiv.org/abs/1801.01078> [Zugriff am: 28.11.2019]
- [73] C. Olah, "Understanding LSTM Networks," 27.08.2015. [Online]. Abgerufen von: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> [Zugriff am: 23.08.2018]
- [74] L. Breiman, J. H. Friedman, R. A. Olshen, und C. J. Stone, *Classification and regression trees*. New York, NY, USA: Chapman & Hall/CRC, 1984.
- [75] M. Dmitrievsky, "Random Decision Forest und Reinforcement Learning," 09.07.2018. [Online]. Abgerufen von: <https://www.mql5.com/de/articles/3856> [Zugriff am: 25.10.2019]
- [76] T. K. Ho, "Random decision forests," In *Proceedings of the third International Conference on Document Analysis and Recognition*, IEEE, Ed. Los Alamitos, CA, USA: IEEE Computer Society Press, 1995, S. 278–282.
- [77] S. J. Pan und Q. Yang, "A Survey on Transfer Learning," In *IEEE Transactions on Knowledge and Data Engineering*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2010, Bd. 22, S. 1345–1359.
- [78] L. Torrey und J. Shavlik, "Transfer Learning," In *Handbook of research on machine learning applications and trends*, E. Soria Olivias, Ed. Hershey, PA, USA: IGI Global, 2010, S. 242–264.
- [79] N. Segev, "Transfer Learning Using DecisionForests," Master Thesis, Israel Institute of Technology Elul, Haifa, Israel, September 2015.

- [80] Y. Guo, H. Shi, A. Kumar, K. Grauman, T. Rosing, und R. Feris, "SpotTune: Transfer Learning through Adaptive Fine-tuning," 2018. [Online]. Abgerufen von: <https://arxiv.org/abs/1811.08737> [Zugriff am: 28.11.2019]
- [81] S. Yoon, H. Yun, Y. Kim, G.-t. Park, und K. Jung, "Efficient Transfer Learning Schemes for Personalized Language Modeling Using Recurrent Neural Network," In *31st Association for the Advancement of Artificial Intelligence, AAAI*, Ed. San Francisco, CA, USA: AAAI Press, 2017, S. 457–463.
- [82] R. Mendel, A. Ebigbo, A. Probst, H. Messmann, und C. Palm, "Barrett's Esophagus Analysis Using Convolutional Neural Networks," In *Bildverarbeitung für die Medizin 2017*, ser. Informatik aktuell, K. H. Maier-Hein, T. M. Deserno, H. Handels, und T. Tolxdorff, Ed. Berlin: Springer Vieweg, 2017, S. 80–85.
- [83] K. M. Hosny, M. A. Kassem, und M. M. Foad, "Skin Cancer Classification using Deep Learning and Transfer Learning," In *2018 9th Cairo International Biomedical Engineering Conference (CIBEC)*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2018, S. 90–93.
- [84] A. Menegola, M. Fornaciali, R. Pires, F. Vasques Bittencourt, S. Avila, und E. Valle, "Knowledge Transfer for Melanoma Screening with Deep Learning," 2017. [Online]. Abgerufen von: <https://arxiv.org/abs/1703.07479> [Zugriff am: 27.02.2019]
- [85] H. I. Fawaz, G. Forestier, J. Weber, L. Idoumghar, und P.-A. Muller, "Transfer learning for time series classification," In *IEEE International Conference on Big Data*, N. Abe, Ed. Piscataway, NJ, USA: IEEE, 2018, S. 1367–1376.
- [86] J. Domeyer, A. Dinparastdjadid, J. D. Lee, G. Douglas, A. Alsaïd, und M. Price, "Proxemics and Kinesics in Automated Vehicle–Pedestrian Communication: Representing Ethnographic Observations," In *Transportation Research Record*, National Academy of Sciences, Ed. Washington, DC: SAGE journals, 2019, S. 70–81.
- [87] F. Bella, V. Natale, M. Silvestri, und F. Nobili, "Drivers' Behavior in Pedestrian Detection: Effects of Road Types," In *ADVANCES IN HUMAN*

- FACTORS AND SYSTEMS INTERACTION*. Orlando, FL, USA: Springer, 2018, S. 813–822.
- [88] B. Färber, “Kommunikationsprobleme zwischen autonomen Fahrzeugen und menschlichen Fahrern,” In *Autonomes Fahren*, ser. Springer open, M. Maurer, Ed. Berlin u.a.: Springer Vieweg, 2015, S. 127–146.
- [89] A. Schaudt und S. Russell, “Judging a Car by its Cover: Human Factors Implications for Automated Vehicle External Communication,” In *Road Vehicle Automation 5*, ser. Lecture Notes in Mobility, G. Meyer und S. Becker, Ed. Cham, Schweiz: Springer International Publishing, 2018, S. 69–76.
- [90] S. K. Jayaraman, C. Creech, L. P. Robert, JR., D. M. Tilbury, X. J. Yang, A. K. Pradhan, und K. M. Tsui, “Trust in AV: An Uncertainty Reduction Model of AV-Pedestrian Interactions: Late-Breaking Report,” In *Proceedings of the Companion of the 2018 ACM/IEEE International Conference on Human-Robot Interaction (HRI 2018), March 5–8, 2018, Chicago, IL, USA*.
- [91] V. M. Lundgren, A. Habibovic, J. Andersson, T. Lagström, M. Nilsson, A. Sirkka, J. Fagerlön, R. Fredriksson, C. Edgren, S. Krupenia, und D. Saluäär, “Will There Be New Communication Needs When Introducing Automated Vehicles to the Urban Context?” In *Advances in Human Aspects of Transportation*, ser. Advances in Intelligent Systems and Computing, N. A. Stanton, Ed. Cham, Schweiz: Springer International Publishing, 2018, S. 485–497.
- [92] Y. E. Song, C. Lehsing, T. Fuest, und K. Bengler, “External HMIs and Their Effect on the Interaction Between Pedestrians and Automated Vehicles,” In *Intelligent Human Systems Integration*, ser. Advances in Intelligent Systems and Computing, W. Karwowski und T. Ahram, Ed. Cham, Schweiz: Springer International Publishing, 2018, S. 13–18.
- [93] T. Imai, D. Sekiguchi, M. Inami, N. Kawakami, und S. Tachi, “Measuring Gaze Direction Perception Capability of Humans to Design Human Centered Communication Systems,” In *Presence*, Massachusetts Institute of Technology, Ed., Boston, MA, USA, 2006, Bd. 15, S. 123–138.
- [94] D. L. Scarl, “Eye contact perception at distances up to six meters,” Dissertation, Portland State University, Portland, OR, USA, 1985.

- [95] K. Liberman, "A study at 30th street," In *Language & Communication*, T. Taylor und J. E. Joseph, Ed., 2018.
- [96] C. R. Hudson, S. Deb, D. W. Carruth, J. McGinley, und D. Frey, "Pedestrian Perception of Autonomous Vehicles with External Interacting Features," In *ADVANCES IN HUMAN FACTORS AND SYSTEMS INTERACTION*. Orlando, FL, USA: Springer, 2018, S. 33–39.
- [97] A. Habibovic, J. Andersson, M. Nilsson, V. M. Lundgren, und J. Nilsson, "Evaluating interactions with non-existing automated vehicles: Three Wizard of Oz approaches," In *IEEE Intelligent Vehicles Symposium (IV)*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2016, S. 32–37.
- [98] P. A. Hancock, E. J. de Visser, J. Y. C. Chen, und R. Parasuraman, "A Meta-Analysis of Factors Affecting Trust in Human-Robot Interaction," In *Human Factors*, SAGE Publications, Ed., Thousand Oaks, CA, USA, 2011, Bd. 5, S. 517–527.
- [99] T. Singer, D. Polin, B. Zandi, J. Kobbert, und T. Q. Khanh, "Investigation and comparison of pedestrian behaviour in different encounter scenarios with automated vehicles," In *Proceedings of the 13th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2019, S. 557–566.
- [100] C. Kettwich, J. Dodiya, M. Wilbring, und A. Schieben, "Light-Based Communication of Automated Vehicles with other Traffic Participants - A Usability Study in a Virtual Reality Environment," In *Proceedings of the 13th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2019, S. 567–576.
- [101] T. Petzoldt, K. Schleinitz, und R. Banse, "Potential safety effects of a frontal brake light for motor vehicles," In *IET Intelligent Transport Systems*, London, England, 2018, Bd. 12, S. 449–453.
- [102] A. Werner, "New Colours for Autonomous Driving: An Evaluation of Chromaticities for the External Lighting Equipment of Autonomous Vehicles: Colour Turn, Nr. 1 (2018): Colour Turn 2018 / Colour Turn, Nr. 1 (2018): Colour Turn 2018," In *Colour Turn*, Tübingen Open Journals, Ed., Tübingen, 2018.

- [103] P. M. Mathea, "Aufbau und Evaluation eines intuitiven, kommunikationslichtbasierten Konzepts zur Fahrzeug-Fußgänger-Kommunikation im urbanen Raum," Master Thesis, RWTH Aachen, Aachen, September 2019.
- [104] J. Reschke, P. Rabenau, M. Hamm, und C. Neumann, "Symbolische Fahrzeug-Fußgänger-Interaktion," In *Optische Technologien in der Fahrzeugtechnik*, VDI Wissensforum GmbH, Ed. Düsseldorf: VDI Verlag GmbH, 2018, S. 95–106.
- [105] J. Reschke, M.-T. Auburger, R. Marichalar, und C. Neumann, "Kommunikation zwischen automatisierten Fahrzeugen und Fußgängern," *ATZ - Automobiltechnische Zeitschrift*, Bd. 121, Nr. 9, S. 16–21, 2019.
- [106] A. Colley, J. Häkikä, M.-T. Forsman, B. Pflöging, und F. Alt, "Car Exterior Surface Displays," In *The Encyclopedia of Middle Grades Education (2nd ed.)*, ser. The Handbook of Resources in Middle Level Education, S. B. Mertens, M. M. Caskey, und N. Flowers, Ed. Charlotte, NC, USA: Information Age Publishing, 8116, S. 1–8.
- [107] W. Huhn, M. Hamm, S. Berlitz, und S. Omerbegovic, "Digitales Licht: Von der Matrix zum Mikrospiegel," *ATZ - Automobiltechnische Zeitschrift*, Bd. 120, Nr. 2, S. 18–25, 2018.
- [108] K. Mahadevan, S. Somanath, und E. Sharlin, "Can Interfaces Facilitate Communication in Autonomous Vehicle-Pedestrian Interaction?" In *HRI 2018*, IEEE, Ed., Chicago, IL, USA, 2018, S. 309–310.
- [109] N. Pennycooke, "AEVITA: Designing Biomimetic Vehicle-to-Pedestrian Communication Protocols for Autonomously Operating & Parking On-Road Electric Vehicles," Master Thesis, Massachusetts Institute of Technology, Boston, MA, USA, September 2012.
- [110] F. Schneemann und P. Heinemann, "Context-based detection of pedestrian crossing intention for autonomous driving in urban environments," In *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2016, S. 2243–2248.
- [111] F. Schneemann, "Erkennung der Querungsintention von Fußgängern für das automatisierte Fahren im städtischen Umfeld," Dissertation, Ruhr Universität Bochum, Bochum, November 2017.

- [112] D. Varytimidis, F. Alonso-Fernandez, B. Duran, und C. Englund, "Action and intention recognition of pedestrians in urban traffic," 2018. [Online]. Abgerufen von: <https://arxiv.org/abs/1810.09805> [Zugriff am: 11.12.2019]
- [113] J. Škovierová, A. Vobecký, M. Uller, R. Škoviera, und V. Hlaváč, "Motion Prediction Influence on the Pedestrian Intention Estimation Near a Zebra Crossing," In *VEHITS 2018*, M. Helfert und O. Gusikhin, Ed. Setúbal, Portugal: SCITEPRESS - Science and Technology Publications Lda, 2018, S. 341–348.
- [114] N. Deo und M. M. Trivedi, "Multi-Modal Trajectory Prediction of Surrounding Vehicles with Maneuver based LSTMs," 2018. [Online]. Abgerufen von: <https://arxiv.org/abs/1805.05499>
- [115] S. Casas, W. Luo, und R. Urtasun, "IntentNet: Learning to Predict Intention from Raw Sensor Data," In *Proceedings of The 2nd Conference on Robot Learning*, ser. Proceedings of Machine Learning Research, A. Billard, A. Dragan, J. Peters, und J. Morimoto, Ed., Bd. 87. PMLR, 2018, S. 947–956.
- [116] A. Polychronopoulos, M. Tsogas, A. J. Amditis, und L. Andreone, "Sensor Fusion for Predicting Vehicles' Path for Collision Avoidance Systems," In *IEEE Transactions on Intelligent Transportation Systems*, IEEE, Ed. IEEE, 2007, Bd. 8, S. 549–562.
- [117] F. Altche und A. de La Fortelle, "An LSTM network for highway trajectory prediction," In *IEEE ITSC 2017*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2017, S. 353–359.
- [118] A. Zyner, S. Worrall, und E. Nebot, "A Recurrent Neural Network Solution for Predicting Driver Intention at Unsignalized Intersections," In *Robotics and Automation Letters*, IEEE Robotics and Automation Society, Ed., 2018, S. 1759–1764.
- [119] B. Kim, C. M. Kang, S. H. Lee, H. Chae, J. Kim, C. C. Chung, und J. W. Choi, "Probabilistic Vehicle Trajectory Prediction over Occupancy Grid Map via Recurrent Neural Network," 2017. [Online]. Abgerufen von: <https://arxiv.org/abs/1704.07049>



- [120] S. H. Park, B. Kim, C. M. Kang, C. C. Chung, und J. W. Choi, "Sequence-to-Sequence Prediction of Vehicle Trajectory via LSTM Encoder-Decoder Architecture," 2018. [Online]. Abgerufen von: <https://arxiv.org/abs/1802.06338> [Zugriff am: 12.12.2019]
- [121] H. Berndt und K. Dietmayer, "Driver intention inference with vehicle onboard sensors," In *IEEE International Conference on Vehicular Electronics and Safety (ICVES), 2009*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2009, S. 102–107.
- [122] P. Kumar, M. Perrollaz, S. Lefevre, und C. Laugier, "Learning-based approach for online lane change intention prediction," In *Intelligent Vehicles Symposium (IV), 2013 IEEE*, IEEE, Ed. IEEE, 2013, S. 797–802.
- [123] U. Dogan, J. Edelbrunner, und I. Iossifidis, "Autonomous driving: A comparison of machine learning techniques by means of the prediction of lane change behavior," In *IEEE International Conference on Robotics and Biomimetics (ROBIO), 2011*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2011, S. 1837–1843.
- [124] D. Tran, W. Sheng, L. Liu, und M. Liu, "A Hidden Markov Model based driver intention prediction system," In *2015 IEEE International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2015, S. 115–120.
- [125] A. Jain, A. Singh, H. S. Koppula, S. Soh, und A. Saxena, "Recurrent Neural Networks for Driver Activity Anticipation via Sensory-Fusion Architecture," 2015. [Online]. Abgerufen von: <https://arxiv.org/abs/1509.05016> [Zugriff am: 10.12.2019]
- [126] A. Zyner, S. Worrall, J. Ward, und E. Nebot, "Long short term memory for driver intent prediction," In *28th IEEE Intelligent Vehicles Symposium*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2017, S. 1484–1489.
- [127] T. Streubel und K. H. Hoffmann, "Prediction of driver intended path at intersections," In *Intelligent Vehicles Symposium Proceedings*, IEEE, Ed., 2014, S. 134–139.
- [128] M. Zhao, D. Kathner, M. Jipp, D. Soffker, und K. Lemmer, "Modeling driver behavior at roundabouts: Results from a field study," In *28th*

- IEEE Intelligent Vehicles Symposium*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2017, S. 908–913.
- [129] L. Zhu, S. Li, Y. Li, M. Wang, Y. Li, und J. Yao, “Study on driver’s braking intention identification based on functional near-infrared spectroscopy,” In *Journal of Intelligent and Connected Vehicles*. Emerald Publishing Limited, 2018, Bd. 1, S. 107–113.
- [130] M. Garcia Ortiz, J. Fritsch, F. Kummert, und A. Gepperth, “Behavior prediction at multiple time-scales in inner-city scenarios,” In *IEEE Intelligent Vehicles Symposium (IV)*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2011, S. 1068–1073.
- [131] ISO, “ISO 26262-9, Road vehicles - Functional Safety: Automotive safety integrity level (ASIL)-oriented and safety-oriented analyses,” 12.2018.
- [132] —, “ISO 26262-1, Road vehicles - Functional Safety: Vocabulary,” 12.2018.
- [133] K. R. Varshney, “Engineering safety in machine learning,” In *2016 Information Theory and Applications Workshop (ITA)*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2016.
- [134] F. Al-Khoury, “Safety of Machine Learning Systems in Autonomous Driving,” Master Thesis, KTH Royal Institute of Technology, Stockholm, Schweden, 2017.
- [135] ISO, “ISO 26262-3, Road vehicles - Functional Safety: Concept phase,” 12.2018.
- [136] J. M. Faria, “Machine Learning Safety: An Overview,” In *Safety-Critical Systems Symposium 2018*, York, England, 2018.
- [137] J. Hull, D. Ward, und R. R. Zakrzewski, “Verification and validation of neural networks for safety-critical applications,” In *Proceedings of the 2002 American Control Conference*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2002, Bd. 6, S. 4789–4794.
- [138] T. Gehr, M. Mirman, D. Drachler-Cohen, P. Tsankov, S. Chaudhuri, und M. Vechev, “AI<sup>2</sup>: Safety and Robustness Certification of Neural Networks with Abstract Interpretation,” In *2018 IEEE Symposium on Security and Privacy*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2018.

- [139] X. Huang, M. Kwiatkowska, S. Wang, und M. Wu, "Safety Verification of Deep Neural Networks," In *Computer aided verification*, ser. Lecture notes in computer science, R. Majumdar und V. Kunčák, Ed. Cham, Schweiz: Springer, 2017, S. 3–29.
- [140] K. R. Varshney und H. Alemzadeh, "On the Safety of Machine Learning: Cyber-Physical Systems, Decision Sciences, and Data Products," 2016. [Online]. Abgerufen von: <https://arxiv.org/abs/1610.01256v2> [Zugriff am: 02.12.2019]
- [141] W. Knight und E. Wolfangel, "Was denkt sich die KI?" *Technology Reviews - Das Magazin für Innovationen*, Nr. 08, S. 31–34, 2017.
- [142] Aptiv, AUDI AG, Baidu, BMW, Continental, Daimler AG, FCA, here, Infionin, Intel, und Volkswagen, *Safety First for Automated Driving*, 2019.
- [143] T. H. Cormen, C. E. Leiserson, R. L. Rivest, und C. Stein, *Introduction to algorithms*, 3. aufl. Cambridge, MA, USA: MIT Press, 2009.
- [144] G. R. Bradski und A. Kaehler, *Learning OpenCV*, 1. aufl., ser. Software that sees. Sebastopol, CA, USA: O'Reilly, 2008.
- [145] A. More und M. C. Deo, "Forecasting wind with neural networks," In *Marine Structures*, M. Fujikubo, J. Niedzwecki, und S. Saevik, Ed. Elsevier, International Ship and Offshore Structures Congress, 2003, Bd. 16, S. 35–49.
- [146] S. Kim, "Introduction to Time Series Data Analysis," 2018. [Online]. Abgerufen von: <https://algorithmia.com/blog/introduction-to-time-series> [Zugriff am: 28.11.2019]
- [147] J. P. DeCruyenaere und H. M. Hafez, "A comparison between Kalman filters and recurrent neural networks," In *International Joint Conference on Neural Networks*, IEEE, Ed. Baltimore, MD, USA: IEEE, 1992, S. 247–251.
- [148] T. Umematsu, A. Sano, S. Taylor, und R. W. Picard, "Improving Students' Daily Life Stress Forecasting using LSTM Neural Networks," In *EMBS International Conference on Biomedical & Health Informatics (BHI)*, IEEE, Ed. Chicago, IL, USA: IEEE, 2019.

- [149] N. Laptev, J. Yosinski, L. E. Li, und S. Smyl, "Time-series Extreme Event Forecasting with Neural Networks at Uber," In *34th International Conference on Machine Learning*, International Machine Learning Society, Ed., Sydney, Australien, 2017.
- [150] D. J. Phillips, T. A. Wheeler, und M. J. Kochenderfer, "Generalizable intention prediction of human drivers at intersections," In *28th IEEE Intelligent Vehicles Symposium*, IEEE, Ed. Piscataway, NJ, USA: IEEE, 2017, S. 1665–1670.
- [151] H. I. Fawaz, G. Forestier, J. Weber, L. Idoumghar, und P.-A. Muller, "Deep Neural Network Ensembles for Time Series Classification," 26.04.2019. [Online]. Abgerufen von: <https://arxiv.org/abs/1903.06602> [Zugriff am: 28.11.2019]
- [152] S. Kaneko, H. Ikemoto, und Y. Kusui, "Approach to designing easy-to-understand icons," In *Proceedings of the 1991 IEEE Workshop on Visual Languages*, IEEE, Ed. Los Alamitos, CA, USA: IEEE Computer Society Press, 1991, S. 246–253.
- [153] M. Clamann, M. Aubert, und M. L. Cummings, "Evaluation of Vehicle-to-Pedestrian Communication Displays for Autonomous Vehicles," In *Transportation Research Board 96th Annual Meeting*, Washington, DC, USA, 2017.
- [154] K. Mahadevan, S. Somanath, und E. Sharlin, "Enabling Pedestrian Communication with Autonomous Vehicles," In *CHI 2018 workshop: Conference on Human Factors in Computing Systems*, Montreal, Kanada, 2018.
- [155] S. J. McDougall, M. B. Curry, und O. de Bruijn, "Measuring symbol and icon characteristics: norms for concreteness, complexity, meaningfulness, familiarity, and semantic distance for 239 symbols," In *Behavior Research Methods, Instruments, & Computers*. Springer US, 1999, Bd. 31, S. 487–519.
- [156] B. L. Collins und N. D. Lerner, "Assessment of Fire-Safety Symbols," In *Human Factors*, SAGE Publications, Ed., Thousand Oaks, CA, USA, 1982, Bd. 24, S. 75–84.
- [157] J. Bortz und N. Döring, *Forschungsmethoden und Evaluation: Für Human- und Sozialwissenschaftler*, 4. aufl., ser. Springer-Lehrbuch Bachelor, Master. Heidelberg: Springer-Medizin-Verl., 2006.

- [158] M. Hamm, W. Huhn, und J. Reschke, "Ideas for Next Lighting Generations in Digitalization and Autonomous Driving: Technical Paper 2018-01-1038," In *World Congress Experience*, SAE International, Ed., Detroit, MI, USA, 2018.
- [159] W. Huhn, M. Hamm, und J. Reschke, "Digitales Licht für Fahrzeuge: Von Matrix-LED-Licht über DMD-Scheinwerfer bis zur OLED-Matrix-Heckleuchte," In *AUTOMOBIL-ELEKTRONIK*, auto & elektronik, Ed. Hüthig GmbH, 2018, S. 64–67.
- [160] A. Field, *Discovering statistics using SPSS: (and sex and drugs and rock 'n' roll)*, 3. aufl. Los Angeles, CA, USA: Sage, 2011.
- [161] E. Jonkisz, H. Moosbrugger, und H. Brandt, "Testtheorie und Fragebogenkonstruktion," In *Testtheorie und Fragebogenkonstruktion*, ser. Springer-Lehrbuch, H. Moosbrugger und A. Kelava, Ed. Berlin u.a.: Springer, 2012, S. 27–74.
- [162] F. Krieff, A. Thoma, B. Willeke, B. Kubitz, und M. Kaup, "Symbol Projections: Gain or Gadget?" In *Proceedings of the 13th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2019, S. 321–330.
- [163] R. Marichalar Quezada und M.-T. Auburger, "Evaluation of Symbol and Color Comprehension in Vehicle-to-Pedestrian Communication for Autonomous Vehicles: An Online Survey on an Innovative Use of Headlights," Project Study, Technische Universität München, München, 27.03.2019.
- [164] J. Reschke, T. Höß, B. Schleyer, S. Berlitz, und C. Neumann, "How Vehicles Learn to Display Symbols to Pedestrians," In *Proceedings of the 13th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2019, S. 590–599.
- [165] J. Reschke, S. Prösl, M. Hamm, und C. Neumann, "Assistance System for Vehicle-Pedestrian-Interaction: Deep Learning and Driver Intention Prediction," In *SIA VISION 2018: Proceedings*, SIA - French Society of Automotive Engineers, Ed., Paris, Frankreich, 2018, S. 19–26.

- [166] AUDI AG, "Audi Elaine." [Online]. Abgerufen von: <https://www.audi.com/en/experience-audi/models-and-technology/concept-cars/audi-elaine.html> [Zugriff am: 10.02.2020]
- [167] Hyundai, "Blue Drive: Freie Fahrt in eine saubere Zukunft. Mit Hyundai Blue Drive." [Online]. Abgerufen von: <https://hyundai.org/Dealer/AutohausWenge/Kundenservice/Aktionen/Seiten/Blue-Drive0612-3922.aspx> [Zugriff am: 10.02.2020]
- [168] AUDI AG, "Parkassistent," 2011. [Online]. Abgerufen von: <https://www.audi-technology-portal.de/de/elektrik-elektronik/fahrerassistenzsysteme/parkassistent> [Zugriff am: 10.02.2020]
- [169] J.-H. Willrodt, H. Strothmann, und J. Wallaschek, "Optical Car-to-Human Communication for Automated Vehicles," In *Proceedings of the 12th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2017, S. 579–588.
- [170] M. Beggiano, I. Neumann, und A.-C. Hensch, "InMotion: Light-based communication between automated vehicles and other road users," Report, Chemnitz University of Technology, Chemnitz.
- [171] M. J. Flanagan, "UMTRI Review: Lighting for Automated Vehicles," Report, UMTRI, University of Michigan, Ann Arbor, MI, USA, 2017.
- [172] S. Westland, "Computational Colour Science using MATLAB 2e," 05.03.2013. [Online]. Abgerufen von: <https://de.mathworks.com/matlabcentral/fileexchange/40640-computational-colour-science-using-matlab-2e> [Zugriff am: 07.02.2020]
- [173] B. Fortner und T. E. Meyer, *Number by Colors: A Guide to Using Color to Understand Technical Data*. New York, NY, USA: Springer New York, 1997.
- [174] "Amazon Mechanical Turk." [Online]. Abgerufen von: [www.mturk.com](http://www.mturk.com) [Zugriff am: 12.02.2020]
- [175] "Prolific." [Online]. Abgerufen von: [www.prolific.co](http://www.prolific.co) [Zugriff am: 12.02.2020]

- [176] S. Ishihara, *Ishihara's Tests for Colour Deficiency: 38 Plates Edition*. Japan: Kanehara Trading Inc., 1988.
- [177] M. Richter, *Einführung in die Farbmatrik*, ser. Sammlung Göschen. Berlin: De Gruyter, 2011.
- [178] A. Hoffmann und M. Menozzi, "Computer-basierte Bestimmung von Rot/Grün-Farbanomalien," In *Biomedical Engineering*, O. Dössel, Ed., 1998, Bd. 43, S. 124–132.
- [179] J. Cohen, *Statistical Power Analysis for the Behavioral Sciences*, 2. aufl. Hoboken, NJ, USA: Taylor and Francis, 2013.
- [180] Y.-C. Hsu, S. Gopalswamy, S. Saripalli, und D. A. Shell, "An MDP Model of Vehicle-Pedestrian Interaction at an Unsignalized Intersection," 2018. [Online]. Abgerufen von: <http://robotics.cs.tamu.edu/dshell/papers/vtc2018mdp.pdf> [Zugriff am: 17.08.2018]
- [181] J.-H. Willrodt, S. Döhler, und J. Wallaschek, "Über die Umsetzung einer gerichteten Signalleuchte für automatisierte Fahrzeuge auf Basis einer asphärischen Fläche," In *Lux junior 2017*, C. Vandahl, Ed. Dörfel/Ilm: Technische Universität Ilmenau, 2017.
- [182] T. Höß, "Driver Intention Prediction at Pedestrian Crossings: Development, Implementation and Validation of different Approaches," Master Thesis, Technische Universität Darmstadt, Darmstadt, 15.03.2019.
- [183] B. Schleyer, "Fahrerintentionserkennung an Fußgängerüberwegen - Implementierung eines Machine-Learning Ansatzes mit Personalisierung und Adaption auf fahrerspezifische Verhaltensweisen," Master Thesis, Fachhochschule Würzburg-Schweinfurt, Schweinfurt, 30.08.2019.
- [184] N. Attia, "Driver Intention Prediction Using Deep Neural Networks," Master Thesis, Technische Universität München, München, 28.07.2020.
- [185] J. Reschke, S. Berlitz, und C. Neumann, "Personalised neural networks for a driver intention prediction: communication as enabler for automated driving," In *Advanced Optical Technologies*, M. Pfeffer, Ed. Berlin: De Gruyter, 2020, Bd. 9.
- [186] Bundesministerium für Verkehr und digitale Infrastruktur, "Straßenverkehrs-Ordnung: StVO," 2019.

- [187] K. Pudenz, "Volkswagen zeigt Start-Stopp 2.0 und Freilauf-Motor-Aus," 2014. [Online]. Abgerufen von: <https://www.springerprofessional.de/automobil---motoren/volkswagen-zeigt-start-stopp-2-0-und-freilauf-motor-aus/6585236> [Zugriff am: 03.06.2019]
- [188] AUDI AG, "Betriebsanleitung: A6 (2019)," Ingolstadt, S. 116–118, 2019.
- [189] S. Omerbegovic, "Prädiktive Lichtfunktionen für volladaptive Scheinwerfersysteme," Dissertation, Karlsruher Institut für Technologie, Karlsruhe, 2019.
- [190] J. Stallkamp, M. Schlipsing, J. Salmen, und C. Igel, "The German Traffic Sign Recognition Benchmark: A multi-class classification competition," In *The 2011 International Joint Conference on Neural Networks (IJCNN)*, A. A. Minai, Ed. Piscataway, NJ, USA: IEEE, 2011, S. 1453–1460.
- [191] D. W. Ruck, S. K. Rogers, und M. Kabrisky, "Feature Selection Using a Multilayer Perceptron," In *Journal of Neural Network Computing*, 1990, S. 40–48.
- [192] A. Várhelyi, "Drivers' speed behaviour at a zebra crossing: a case study," In *Accident Analysis & Prevention*, 1998, Bd. 30, S. 731–743.
- [193] "Ergebnisse Fahrleistungserhebung 2014: Erhebung der Inländerfahrleistung und der Inlandsfahrleistung." [Online]. Abgerufen von: [https://www.bast.de/BAST\\_2017/DE/Verkehrssicherheit/Fachthemen/u2-fahrleistung-2014/u2-Fahrleistung-2014-ergebnisse.html](https://www.bast.de/BAST_2017/DE/Verkehrssicherheit/Fachthemen/u2-fahrleistung-2014/u2-Fahrleistung-2014-ergebnisse.html) [Zugriff am: 03.01.2020]
- [194] "Verkehr in Kilometern: Inländerfahrleistung." [Online]. Abgerufen von: [https://www.kba.de/DE/Statistik/Kraftverkehr/VerkehrKilometer/verkehr\\_in\\_kilometern\\_node.html](https://www.kba.de/DE/Statistik/Kraftverkehr/VerkehrKilometer/verkehr_in_kilometern_node.html) [Zugriff am: 03.01.2020]
- [195] "Graphhopper maps," Cambridge, UK. [Online]. Abgerufen von: <https://www.graphhopper.com/> [Zugriff am: 16.12.2019]
- [196] R. Ellouze, "Driver Intention Recognition based on Camera Data," Bachelor Thesis, Technische Universität München, München, 30.09.2018.





---

# TABELLENVERZEICHNIS

4.1. Durchschnittliche Bewertung der Aussagekraft ausgewählter Symbole . . . . .	60
4.2. Sequentielle Darstellung der dynamischen Symbole für das Erkennen eines Fußgängers, nach [163] . . . . .	65
4.3. Ergebnisse des einseitigen t-Tests für die Auswertung der Aussagekraft der Symbole, nach [163] . . . . .	75
4.4. Ergebnisse des z-Tests für die Auswertung der Erkennungsraten der Symbole (offene Antworten), nach [163] . . . . .	76
4.5. Ergebnisse des einseitigen t-Tests für die Auswertung der Sicherheit/Konfidenz der offenen Antworten, nach [163] . . . . .	77
4.6. Ergebnisse des z-Tests für die Auswertung der Erkennungsraten der Symbole (vorgegebene Antworten), nach [163] . . . . .	77
4.7. Ergebnisse des einseitigen t-Tests für die Auswertung der Sicherheit/Konfidenz der vorgegebenen Antworten, nach [163] . . . . .	79
4.8. Mittlere Konfidenzbewertung der untersuchten Symbole für die Darstellung eines automatisierten Fahrmodus, nach [163] . . . . .	80
4.9. Mittlere Konfidenzbewertung der untersuchten Symbole für Vorfahrt gewähren für Fußgänger, nach [163] . . . . .	81
4.10. Mittlere Konfidenzbewertung der untersuchten Symbole für das Erkennen eines Fußgängers, nach [163] . . . . .	82
5.1. Feature Auswahl mittels ANN, nach [182] . . . . .	101
5.2. Vergleich Min-Max und Tanh Normalisierung für das RNN57: Absolute Abweichung des prädizierten Geschwindigkeitswert zum Label, nach [182] . . . . .	106
5.3. Vergleich verschiedener Aktivierungsfunktionen für das aufgebaute RNN und einen ausgewählten Testdatensatz, nach [184] . . . . .	110
5.4. Vergleich verschiedener Transfer Learning Methoden und die Verbesserung der MSE durch diese [185] . . . . .	116

---

5.5. Trainings-, Validierungs- und Test-MSE für das vortrainierte und die nachtrainierten Netzwerke, nach [184] . . . . .	131
A.1. Ergebnisse der korrigierten ANOVA mit Messwiederholung, nach [163] . . . . .	201
B.1. Regelsatz für das Labeling der Daten zur Bestimmung der Fahrerintention, nach [182] . . . . .	203
B.2. Aufgenommene Signale (FlexRay) für die Fahrerintentionserkennung; Verwendete Features für den Algortihmus in fett . . . . .	206

---

# ABBILDUNGSVERZEICHNIS

2.1.	Allgemeines Kommunikationsmodell nach Shannon [16] . . . . .	6
2.2.	Stufen des automatisierten Fahrens, nach [9] . . . . .	11
2.3.	Beispiele für Underfitting (a), gute Generalisierung (b) und Overfitting (c) einer quadratischen Funktion, nach [39] . . . . .	13
2.4.	Wahrheitsmatrix, nach [43] . . . . .	14
2.5.	Beispielbild für eine ROC-Kurve, nach [43] . . . . .	16
2.6.	$k$ -fache Cross-Validation, nach [47] . . . . .	17
2.7.	Künstliches Neuron, nach [39][50] . . . . .	20
2.8.	Beispiel für ein kleines neuronales Netzwerk mit drei fully connected Layern und $m$ Ausgängen, nach [50] . . . . .	21
2.9.	Beispiele für Aktivierungsfunktionen $g(z)$ , nach [50][56] . . . . .	22
2.10.	Lernkurven für Trainings- und Validierungsdaten, nach [39] . . . . .	25
2.11.	Hidden State eines Recurrent Neural Networks in kompakter und zeitlich entfalteter Darstellung, nach [39] . . . . .	30
2.12.	Aufbau einer Long Short-Term Memory Zelle, nach [39][73] . . . . .	33
2.13.	Aufbau von Random Forests, nach [75] . . . . .	35
2.14.	Funktionsprinzip von klassischen ANNs (a) und Transfer Learning (b), nach [77] . . . . .	37
3.1.	Beispiel für eine kodierte Leuchte in Form eines eindimensionalen Leuchtenarrays (a) und Display zur Anzeige von Symbolen (b), nach [103] . . . . .	44
4.1.	In der Voruntersuchung evaluierte Zeichen [104] . . . . .	56
4.2.	Mittlere Erkennungsraten ausgewählter Symbole für freie und vorgegebene Antwortmöglichkeiten . . . . .	58
4.3.	Ausgewählte Symbole für weitere Untersuchungen und Kommunikationskonzepte, nach [104] . . . . .	62
4.4.	Symbole und Farben für die Onlinestudie [105] . . . . .	64
4.5.	Normfarbtafel nach Westland [172] mit Farbnamen nach Fortner und Meyer [173] . . . . .	68

---

4.6. Situationsbeschreibung des Versuchsaufbaus, nach [165] . . . . .	71
4.7. Audi Aicon mit angezeigtem Symbol C2 [105] . . . . .	72
4.8. Altersverteilung der Probanden in der Onlinestudie, nach [163] . . . . .	73
4.9. Ausgewählte Symbole der Onlinestudie für eine verständliche Fahrzeug-Fußgänger-Kommunikation, nach [163] . . . . .	79
4.10. Mittlere Konfidenzbewertung der Farben für die drei unter- suchten Nachrichten [105] . . . . .	83
5.1. Blickkontakt zwischen Fahrer und Fußgänger in einer Anhalte- situation [164] . . . . .	92
5.2. Verteilung der minimalen Geschwindigkeiten an Zebrastreifen, nach [165] . . . . .	93
5.3. Beispiele für die Aufteilung der Trainings- (blau, rot) und Test- daten (grün) . . . . .	96
5.4. Accuracy des Decision Trees für das generalisierte Labeln der Daten, nach [182] . . . . .	98
5.5. Beispiel für Geschwindigkeitsprofil an Zebrastreifen mit Start- punkt (A) und Endpunkt (B) der Verzögerung, nach [165] . . . . .	102
5.6. Referenzstrecke zur Aufzeichnung von personalisierten Train- ingsdaten [195] . . . . .	104
5.7. Referenzstrecke zur Aufzeichnung von personalisierten Testda- ten [195] . . . . .	105
5.8. Aufbau des Algorithmus zur Fahrerintentionserkennung in drei Stufen, nach [164] . . . . .	108
5.9. Aufbau des DNN in Stufe 1, nach [164] . . . . .	109
5.10. Grid-Search für den am besten geeigneten Random Forest, nach [183] . . . . .	112
5.11. Verlauf der Trainings- und Validierungs-MSEs beim Vortrainie- ren der ersten Stufe, nach [184] . . . . .	115
5.12. ROC-Kurven des vortrainierten Algorithmus, nach [185] . . . . .	118
5.13. ROC-Kurven nach Stufe 3 für Anhalten an Zebrastreifen und sonstige Situationen, nach [184] . . . . .	120
5.14. Mittlere Abweichung der Prädiktion vom Label in zeitlicher Abhängigkeit zum Zebrastreifen, nach [184] . . . . .	122

5.15. Beispiel für einen Geschwindigkeitsverlauf und auftretende FPs in zeitlicher Abhängigkeit zum Zebrastreifen, nach [184] . . .	123
5.16. Mittlere RPR und FPR in zeitlicher Abhängigkeit zum Zebrastreifen, nach [184] . . . . .	124
5.17. ROC-Kurven des nachtrainierten Algorithmus nach Stufe 2, angepasst an jeweils einen Fahrer und ein Fahrzeug, nach [185]	125
5.18. ROC-Kurven des nachtrainierten Algorithmus nach Stufe 3, angepasst an jeweils einen Fahrer und ein Fahrzeug, nach [185]	126
5.19. Differenzbild der ROC-Kurven von Stufe 3 und Stufe 2 des nachtrainierten Algorithmus, angepasst an jeweils einen Fahrer und ein Fahrzeug, nach [184] . . . . .	127
5.20. ROC-Kurven des nachtrainierten Algorithmus nach Stufe 2, angepasst an vier Fahrer und ein Fahrzeug, nach [184] . . . . .	128
5.21. ROC-Kurven des nachtrainierten Algorithmus nach Stufe 3, angepasst an vier Fahrer und ein Fahrzeug, nach [184] . . . . .	129
6.1. Ausgewählte Symbole für ein Konzept zur Fahrzeug-Fußgänger-Kommunikation, nach [104][163] . . . . .	139
A.1. Mittlere Erkennungsraten aller Symbole für freie und vorgegebene Antwortmöglichkeiten . . . . .	185
B.1. Bestimmung der optimalen Länge der Referenzstrecke, nach [185]208	
B.2. Bestimmung einer optimalen Sequenzlänge für die Eingänge des RNN, nach [182] . . . . .	212



---

# ABKÜRZUNGSVERZEICHNIS

<b>ANOVA</b>	Analysis of Variance
<b>ANN</b>	Artificial Neural Network
<b>ARIMA</b>	Auto Regressive Integrated Moving Average
<b>ARMA</b>	Auto Regressive-Moving Average
<b>ASIL</b>	Automotive Safety Integrity Level
<b>CRF</b>	Conditional Random Field
<b>CV</b>	Cross-Validation
<b>DNN</b>	Deep Neural Network
<b>ER</b>	Erkennungsrate
<b>ESS</b>	Emergency Stop Signal
<b>FC</b>	fully connected
<b>FN</b>	Falsch-Negativ
<b>FNN</b>	Feedforward Neural Network
<b>FP</b>	Falsch-Positiv
<b>FPR</b>	Falsch-positiv Rate
<b>GMM</b>	Gaussian Mixture Model
<b>GTB</b>	Groupe de Travail Bruxelles 1952
<b>HMM</b>	Hidden Markov Model
<b>ISO</b>	International Organisation for Standardization
<b>LSTM</b>	Long Short-Term Memory
<b>MSE</b>	Mean Squared Error
<b>MTurk</b>	Amazon Mechanical Turk

---



<b>NHTSA</b>	National Highway Traffic Safety Administration
<b>RECAS</b>	Rear-End Collision Alert Signal
<b>ReLU</b>	Rectified Linear Unit
<b>RN</b>	Richtig-Negativ
<b>RNN</b>	Recurrent Neural Network
<b>ROC</b>	Receiver Operating Characteristic
<b>RP</b>	Richtig-Positiv
<b>RPR</b>	Richtig-positiv Rate
<b>SAE</b>	Society of Automotive Engineers
<b>SGLA</b>	Symbolic Grammar Learning Algorithm
<b>SVM</b>	Support Vector Machine
<b>tanh</b>	Tangens hyperbolicus



# FORMELZEICHEN

$a$	Beschleunigung
$cov$	Kovarianz
$eps$	Maschinengenauigkeit
$E_{test}$	Testfehler
$E_{training}$	Trainingsfehler
$f_i^{(t)}$	Forget Gate (LSTM)
$g(\cdot)$	Aktivierungsfunktion
$g_i^{(t)}$	Input Gate (LSTM)
$h$	Hidden State eines RNNs
$k$	Anzahl der Teile für eine k-fache CV
$m_1$	Vektor der Schätzung des ersten Moments (Adam Optimizer)
$\hat{m}_1$	um den Bias korrigierter Vektor der Schätzung des ersten Moments (Adam Optimizer)
$m_2$	Vektor der Schätzung des zweiten Moments (Adam Optimizer)
$\hat{m}_2$	um den Bias korrigierter Vektor der Schätzung des zweiten Moments (Adam Optimizer)
$N_a$	Anzahl aller Antworten
$N_k$	Anzahl korrekter Antworten
$N_{\hat{y}}$	Anzahl der prädizierten Werte $\hat{y}$
$N_Z$	Anzahl der Zeichen in der Probandenstudie
$q_i^{(t)}$	Output Gate (LSTM)
$r$	Korrelationskoeffizient
$s_i^{(t)}$	Zellenzustand (LSTM)
$t$	Zeit
$T_A$	Prädiktionshorizont: Zeit, wie lange vor einem Anhalten die Fahrerintention bestimmt wird
$U_i^f$	Gewichtevektor (LSTM)
$v$	Geschwindigkeit
$v_0$	Startgeschwindigkeit vor der Verzögerung
$W$	Gewichtematrix bestehend aus Gewichten $w$
$x$	Eingangsdatenvektor

$x_a$	Abstand des Fahrzeugs zum Fußgängerüberweg
$x_b$	Strecke bis zum vollständigen Anhalten
$x_f$	Strecke von der Fahrerposition zur Fahrzeugfront
$x_s$	maximale Entfernung für einen Blickkontakt
$x_v$	zurückgelegte Strecke während der Verzögerung
$x_0$	Startpunkt der Verzögerung
$y$	Label zum Eingangsdatenvektor
$\hat{y}$	Prädiktion zum Eingangsdatenvektor
$z$	Gewichtete Summe der Eingangsdaten
$\alpha$	Schrittweite (Adam Optimizer)
$\beta_1$	exponentielle Abklingrate des ersten Moments (Adam Optimizer)
$\beta_2$	exponentielle Abklingrate des zweiten Moments (Adam Optimizer)
$\epsilon$	Lernrate
$\mu_j$	Mittelwert der Datenpunkte aus dem Feature $j$
$\sigma_j$	Standardabweichung der Datenpunkte aus dem Feature $j$
$\theta$	Bias
$\omega$	Gewichte- und Biasmatrix



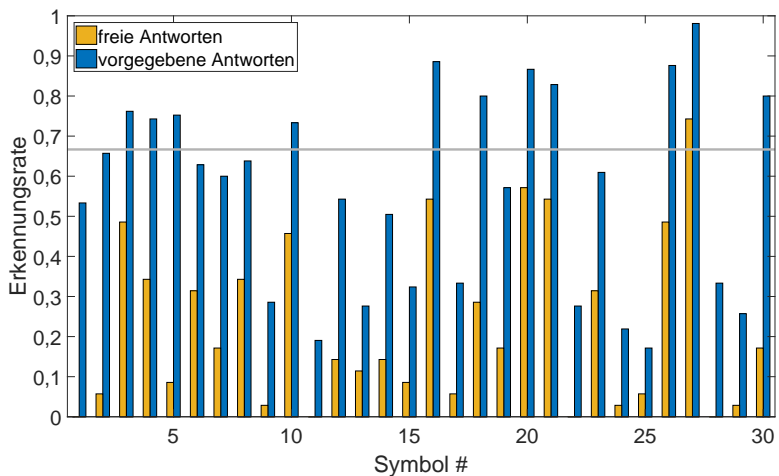
---

# ANHANG

## A UNTERLAGEN ZU DEN STUDIEN

### A.1. VORUNTERSUCHUNG

In folgender Abbildung sind die Erkennungsraten aller Zeichen der Voruntersuchung dargestellt.



**Abbildung A.1.:** Mittlere Erkennungsraten aller Symbole für freie und vorgegebene Antwortmöglichkeiten

---

## A.2. ONLINESTUDIE

Nachfolgend sind Screenshots der Onlinestudie von Marichalar Quezada und Auburger aufgeführt [163].

**Why do we collect and use your data**

**Informed Consent Form**

**Introduction**  
This study attempts to collect information on your perception of different symbols.

**Procedures**  
The survey consists of 3 parts.  
You will be presented with a scenario that describes a traffic situation and asked to complete a questionnaire. This questionnaire will be conducted with an online Unipark-created survey.

**Duration**  
25-30 minutes (approx.)  
Maximum allowed time: 45 minutes

**Risks/Discomforts**  
There appear to be no risks and discomforts associated with the study.

**Confidentiality**  
All data obtained from participants will be kept confidential and will only be reported in an aggregate format (by reporting only combined results and never reporting individual ones).

**Compensation**  
You will receive the compensation as indicated on the MTurk/Prolific website.  
Please make sure to write your MTurk/Prolific ID at the end of the study.

**Attention!**  
If you fail the attention test, the color vision test or fail to complete the survey, you will not be compensated.

**Participation**  
Participation in this research study is completely voluntary. You have the right to withdraw at anytime or refuse to participate entirely.

**Questions about the Research**  
If you have questions regarding this study, you may send an email to [symbolsandiconsurvey@gmail.com](mailto:symbolsandiconsurvey@gmail.com)

For further information about Unipark's Data Security and Privacy Policy, please visit <https://www.unipark.com/en/data-security/>

If you would like to obtain more information about the processing of your personal data, please click [here](#)

I agree to the processing of my personal data in accordance with the information provided herein

[I don't want to participate](#)

---

2%

In the course of this survey, you will look at different images and videos, therefore the following points are very important:

- This survey was optimized for use on a laptop or desktop PC. Therefore, please **do not fill in** this survey on a **mobile phone**
- Please ensure a **stable internet connection** so the videos run smoothly
- Additionally, please ensure that you can see your screen well, avoid reflexions on the screen and wear your prescription glasses/ lenses in case you need them
- Please close any background videos or music
- Please open the survey in **full-screen** (F11 on your keyboard)

Question 1:

If you have read and understood the conditions above and made all relevant changes to ensure that the survey runs smoothly, please click "yes" to continue with the survey.

- yes
- no

Continue

4%

Question 2:

**Do you wear glasses or contact lenses?**


*Please check "yes" if you use any form of visual aids in at least one of your daily activities (e.g. when driving or reading)*

- yes
- no

Question 3:

Please take a close look at the following image:

What number do you see?



- 47
- 49
- 15
- 75
- I don't see any number

Continue





Question 4  
Please take a close look at the following symbol:



Can you see the symbol in the image below?



- yes
- no

Continue

8%

Please have a closer look, the symbol is inside the red rectangles.



Question 5:  
Can you see it now?

- yes
- no

Continue

8%

Question 5:

**Which kind of symbol can you see in the picture below?**

*Often in surveys, people don't read the full questions and risk answering incorrectly. We therefore ask you to choose the option "Sad face" down below.*



- Happy face
- Sad face

Continue

10%


Instructions

(!) Read carefully (!)

Imagine you are walking on a sidewalk next to a busy road and you need to cross to the other side. You look to your right side and see that a car is driving towards you at approximately **10 km/h (6 mph)**. You want to cross in front of the car. To answer the questions in this survey, please imagine that you take on the role of this pedestrian.

Picture 1:

This is a diagram of your position on the sidewalk.



Picture 2:

This picture shows what you would see from the perspective you are standing from.



Question 6:

Do you understand the role you are in?

- yes
- no

Continue

13%


Part 1

**Instructions:**

Imagine you are in the situation described before.  
You will see the image of the car, this time with different symbols at the front, where the red rectangles are now.

For each symbol, there will be 3 questions.

Remember, there are no right or wrong answers! We are interested in your honest opinion.



Continue

15%

Question 7:


Please have a look at the symbol in this image:



How well do you think you understand the meaning of the symbol?

Assess your answer on a scale from 1 to 6.

To indicate your response, please use the bar below and click under your preferred choice.



Question 8:

Write down in a few words what you think the symbol in the image means.


What message does the car want to convey?

Max. 100 characters

Question 9:

How confident do you feel that your last answer is right?

To indicate your response, please use the bar below and click under your preferred choice.



Continue

35%



Congratulations!  
You finished the first part of the survey



Continue

37%

## Part 2

### Instructions:

Imagine you are in the same situation as before.

This time however, you can **select one of 3 possible meanings** for the symbol.

Continue

40%

Please have a look at the symbol in the video:  
Please click on the "play" button to start the video.




Question 34:

Please select the meaning of the symbol you saw on the video from the following list.  
Select the option that you think fits closest to the meaning.

- The car has Wi-Fi
- The pedestrian should not approach the car
- The car has detected the pedestrian

Question 35:

How confident do you feel that your last answer is right?  
To indicate your response, please use the bar below and click under your preferred choice.



Continue



60%

Excellent!  
You finished the second part of the survey



Continue

62%

Question 52:

**Part 3.**

**Instructions:**

In this part, you will see images or videos of the car again, however this time the symbols are shown in different colors.

Underneath each image/video, there will be a written statement, giving you the intended meaning of the symbol and the question we ask you to answer.

*Example question:*




Meaning: "The driver of the car is happy"

How confident are you, that the symbol in the image corresponds to the provided meaning?

To indicate your level of confidence, please use the bar below and click under your preferred choice.

I am certainly wrong



I am certainly right

Continue

# UNTERLAGEN ZU DEN STUDIEN

Please have a look at the following images and answer the question below each of them.

Caption:



Meaning: "The Protection can cross the street now!"

How confident are you that the symbol in the image corresponds to the provided meaning?

To what extent do you agree with the statement? (1 = I do not agree at all, 5 = I agree completely)

1	2	3	4	5
---	---	---	---	---

Caption:



Meaning: "The Protection can cross the street now!"

How confident are you that the symbol in the image corresponds to the provided meaning?

To what extent do you agree with the statement? (1 = I do not agree at all, 5 = I agree completely)

1	2	3	4	5
---	---	---	---	---

Caption:



Meaning: "The Protection can cross the street now!"

How confident are you that the symbol in the image corresponds to the provided meaning?

To what extent do you agree with the statement? (1 = I do not agree at all, 5 = I agree completely)

1	2	3	4	5
---	---	---	---	---

Caption:



Meaning: "The Protection can cross the street now!"

How confident are you that the symbol in the image corresponds to the provided meaning?

To what extent do you agree with the statement? (1 = I do not agree at all, 5 = I agree completely)

1	2	3	4	5
---	---	---	---	---

Caption:



Meaning: "The Protection can cross the street now!"

How confident are you that the symbol in the image corresponds to the provided meaning?

To what extent do you agree with the statement? (1 = I do not agree at all, 5 = I agree completely)

1	2	3	4	5
---	---	---	---	---

Caption:



Meaning: "The Protection can cross the street now!"

How confident are you that the symbol in the image corresponds to the provided meaning?

To what extent do you agree with the statement? (1 = I do not agree at all, 5 = I agree completely)

1	2	3	4	5
---	---	---	---	---

84%



**You are almost finished.**  
Thank you for your collaboration, you did a great job!  
Now, we only need a few details about you.



Continue

87%

Question 107:

Please indicate your age.

Choose the group of age you belong to.

Choose the group of age you belong to:

Question 108:

Please indicate your gender.

Choose your gender:

Question 109:

Do you live in a rural, suburban or urban area?

Please select the choice that fits closest with the type of area you live in

rural  
 suburban  
 urban

Question 110:

In an average week, how many days per week do you use the following means of transportation to travel to/ from destinations in your daily activities (eg. going to work, school, grocery shopping, etc.)?

	every day	on 5-6 days per week	on 3-4 days per week	on less than 3 days per week	never
Car: I drive the car	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Car: I am a passenger in the car (this includes taxi)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Bicycle	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Public Transport (e.g. Bus, Metro, Tram)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Scooter/ Motorcycle	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Walking (as a pedestrian)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Question 111:

As a pedestrian, in an average week, how often do you experience walking in areas with light traffic (no cars or only a few cars on the road)?

every day  
 on 5-6 days per week  
 on 3-4 days per week  
 on less than 3 days per week  
 never  
 I'm usually not a pedestrian

Question 112:

Which country are you from?

please choose your country:

Question 113:

Which color would you expect to see in a symbol when the car wants to tell you that it is in Autonomous Driving Mode?

Please choose a color:

Question 114:

Which color would you expect to see in a symbol when the car wants to tell you "The pedestrian can cross"?

Please choose a color:

Question 115:

Which color would you expect to see in a symbol when the car wants to tell you it has detected you as the pedestrian?

Please choose a color:

Question 116:

Please select your favorite color:

Choose your favorite color:

Question 117:

Were you confident with the level of English used in this survey?

yes  
 no

Question 118:

Did you encounter any technical problems in displaying the images or videos at any point of the survey? (example: the video sequences were not working, or the images were not shown correctly)

yes  
 no

Question 119:

Do you currently have a driver's license?

yes  
 no

Continue

89%

Question 120:

When did you obtain your driver's license?

less than 5 years ago ▾

Continue

91%

Question 121:

Please select the online platform you used to find this study:

- Amazon Mechanical Turk (MTurk)
- Prolific

Continue

100%

Thank you for your time!

Remember to go back to the MTurk website and type in your WorkerID there as well, so we can compensate you.

In case of any further questions you can contact the researchers under the following e-mail address:

[symbolsandiconsurvey@gmail.com](mailto:symbolsandiconsurvey@gmail.com)

We wish you a nice day!

(Press F11 to quit fullscreen mode)

**Tabelle A.1.:**

Ergebnisse der korrigierten ANOVA mit Messwiederholung, nach [163]

<b>Symbol</b>	<b>F-Statistik</b>	<b>p-Wert</b>
AD1	$F(4, 222; 2988, 850) = 63,50$	$< 0,001$
AD2	$F(4, 357; 3084, 686) = 78,19$	$< 0,001$
AD3	$F(4, 258; 3014, 382) = 114,37$	$< 0,001$
C1	$F(3, 872; 2741, 322) = 282,30$	$< 0,001$
C2	$F(3, 667; 2596, 347) = 362,92$	$< 0,001$
C3	$F(3, 811; 3540; 000) = 378,85$	$< 0,001$
D1	$F(4, 056; 2871, 460) = 166,06$	$< 0,001$
D2	$F(3, 794; 2685, 895) = 71,17$	$< 0,001$
D3	$F(4, 092; 2896, 97) = 65,512$	$< 0,001$



---

## B WEITERE ERGEBNISSE ZUR FAHRERINTENTIONSERKENNUNG

In diesem Kapitel werden ergänzende Ergebnisse zur Fahrerintentionserkennung präsentiert, die als zusätzliche Information zu den in Kapitel 5 dargestellten Inhalten dienen.

### B.1. REGELSATZ ZUR BESTIMMUNG DER FAHRERINTENTION

**Tabelle B.1.:**

Regelsatz für das Labeling der Daten zur Bestimmung der Fahrerintention, nach [182]

#	Regel	Halten
0	Start	
1	<i>Minimum Geschwindigkeit</i> $> 50 \frac{km}{h}$	0
2	<i>Maximum Geschwindigkeit</i> $< 6 \frac{km}{h}$	1
3	<i>Minimum Geschwindigkeit</i> $> 30 \frac{km}{h}$	0
4	<i>Geschwindigkeit stetig steigend</i>	0
5	<i>Geschwindigkeit stetig fallend</i> & ( <i>Endgeschwindigkeit</i> $< 10 \frac{km}{h}$ )	1
6	<i>Durchschnittliche Beschleunigung in y</i> $> 1 \frac{m}{s^2}$	0
7	<i>Durchschnittliche Beschleunigung in x</i> $> -2 \frac{m}{s^2}$	1
8	<i>Minimum Bremsdruck</i> $> 5 \text{ bar}$	1
9	<i>Minimum Bremsdruck</i> $> 3 \text{ bar}$	1
10	( <i>Startgeschwindigkeit</i> $+ 5 \frac{km}{h}$ ) $<$ <i>Endgeschwindigkeit</i>	0
11	( <i>Durchschnittliche Geschwindigkeit</i> $> 20 \frac{km}{h}$ ) & ( <i>Standardabweichung</i> $< 1 \frac{km}{h}$ )	0

---



#	Regel	Halten
12	(Durchschnittliche Geschwindigkeit $> 15 \frac{km}{h}$ )& (Standardabweichung $< 1 \frac{km}{h}$ )& (Durchschnittlicher Bremsdruck $< 0,5 \text{ bar}$ )	0
13	(Durchschnittliche Geschwindigkeit $> 20 \frac{km}{h}$ )& (Standardabweichung $< 1,2 \frac{km}{h}$ )	0
14	(Durchschnittliche Geschwindigkeit $> 15 \frac{km}{h}$ )& (Standardabweichung $< 0,5 \frac{km}{h}$ )	0
15	(Minimum Geschwindigkeit $> 10 \frac{km}{h}$ )& (Durchschnittlicher absoluter Lenkwinkel $> 45^\circ$ )	0
16	(Durchschnittliche Geschwindigkeit $> 20 \frac{km}{h}$ )& (Durchschnittlicher absoluter Lenkwinkel $> 20^\circ$ )	0
17	Durchschnittliche Beschleunigung in $x < -1,5 \frac{m}{s^2}$	1
18	Minimum absoluter Lenkwinkel $> 90^\circ$	0
19	Durchschnittliche Geschwindigkeit $< 6 \frac{km}{h}$	1
20	(Startgeschwindigkeit $> 10 \frac{km}{h}$ )& (Startgeschwindigkeit $<$ Endgeschwindigkeit)	0
21	(Durchschnittliche Geschwindigkeit $> 15 \frac{km}{h}$ )& (Durchschnittliche Beschleunigung in $x > -1 \frac{m}{s^2}$ )	0
22	(Durchschnittliche Geschwindigkeit $> 10 \frac{km}{h}$ )& (Durchschnittlicher absoluter Lenkwinkel $> 75^\circ$ )	0
23	Durchschnittlicher Bremsdruck $> 5 \text{ bar}$	1
24	Endgeschwindigkeit $> 20 \frac{km}{h}$	0
25	(Durchschnittliche Geschwindigkeit $< 10 \frac{km}{h}$ )& (Standardabweichung $< 1 \frac{km}{h}$ )	1
26	Maximum absoluter Lenkwinkel $> 180^\circ$	0
27	(Endgeschwindigkeit $- 4 \frac{km}{h}$ ) $>$ Minimum Geschwindigkeit	0
28	Durchschnittliche Beschleunigung in $x < -1 \frac{m}{s^2}$	1
29	(Aenderung Lenkwinkel $> 90^\circ$ )& (Standardabweichung Geschwindigkeit $< 2 \frac{km}{h}$ )	0

#	Regel	Halten
30	Durchschnittliche Geschwindigkeit $> 18 \frac{km}{h}$	0
31	Durchschnittlicher Bremsdruck $> 3 \text{ bar}$	1
32	(Durchschnittlicher absoluter Lenkwinkel $> 45^\circ$ )& (Bremsdruck $< 0,5 \text{ bar}$ )	0
33	Durchschnittliche Beschleunigung in $x < -0,5 \frac{m}{s^2}$	1
34	Durchschnittlicher Bremsdruck $> 1 \text{ bar}$	1
35	(Durchschnittliche Geschwindigkeit $> 12 \frac{km}{h}$ )& (Aenderung Geschwindigkeit $< 1 \frac{km}{h}$ )	0
36	(Durchschnittliche Geschwindigkeit $> 10 \frac{km}{h}$ )& (Aenderung Geschwindigkeit $< 2 \frac{km}{h}$ )& (Aenderung Lenkwinkel $> 15^\circ$ )	0
37	Maximum absoluter Lenkwinkel $> 20^\circ$	0
38	Durchschnittliche Geschwindigkeit $> 10 \frac{km}{h}$	0
39	Durchschnittliche Geschwindigkeit $\leq 10 \frac{km}{h}$	1

## B.2. AUFGENOMMENE FEATURES

**Tabelle B.2.:**

Aufgenommene Signale (FlexRay) für die Fahrerintentionserkennung; Verwendete Features für den Algorithmus in fett

#	Signal	#	Signal
<b>1</b>	<b>KBI_angez_Geschw</b>	<b>2</b>	<b>ESC_Bremsdruck_02</b>
3	ESC_Fahrerbremswunsch	<b>4</b>	<b>MO_Fahrpedalrohwert_01</b>
5	PACC_naechstes_Event	6	ACC_Geschw_Zielfahrzeug
7	ACC_Abstand_Abstandswarner	8	ACC_Texte_Sekundaeranz
9	ACC_Texte_Primaeranz_02	<b>10</b>	<b>LWI_Lenkradwinkel</b>
<b>11</b>	<b>LWI_VZ_Lenkradwinkel</b>	<b>12</b>	<b>LWI_Lenkradw_Geschw</b>
<b>13</b>	<b>LWI_VZ_Lenkradw_Geschw</b>	<b>14</b>	<b>BV2_Obj_01_Klasse</b>
<b>15</b>	<b>BV2_Obj_01_GeschwY</b>	<b>16</b>	<b>BV2_Obj_01_GeschwX</b>
17	BV2_Obj_01_RadialDist	<b>18</b>	<b>BV2_Obj_01_TTC</b>
19	BV2_Obj_01_PositionX	20	BV2_Obj_01_PositionY
21	BV2_Obj_02_Klasse	22	BV2_Obj_02_GeschwY
23	BV2_Obj_02_GeschwX	24	BV2_Obj_02_RadialDist
25	BV2_Obj_02_TTC	26	BV2_Obj_02_PositionX
27	BV2_Obj_02_PositionY	28	BV2_Obj_03_Klasse
29	BV2_Obj_03_GeschwY	30	BV2_Obj_03_GeschwX
31	BV2_Obj_03_RadialDist	32	BV2_Obj_03_TTC
33	BV2_Obj_03_PositionX	34	BV2_Obj_03_PositionY
35	BV2_Obj_04_Klasse	<b>36</b>	<b>BV2_Obj_04_GeschwY</b>
<b>37</b>	<b>BV2_Obj_04_GeschwX</b>	38	BV2_Obj_04_RadialDist
39	BV2_Obj_04_TTC	40	BV2_Obj_04_PositionX
<b>41</b>	<b>BV2_Obj_04_PositionY</b>	<b>42</b>	<b>BV2_Obj_05_Klasse</b>
43	BV2_Obj_56_GeschwY	44	BV2_Obj_57_GeschwX
45	BV2_Obj_05_RadialDist	<b>46</b>	<b>BV2_Obj_05_TTC</b>
47	BV2_Obj_05_PositionX	48	BV2_Obj_05_PositionY

#	Signal	#	Signal
49	<b>BV2_Obj_06_Klasse</b>	50	BV2_Obj_06_GeschwY
51	<b>BV2_Obj_06_GeschwX</b>	52	BV2_Obj_06_RadialDist
53	BV2_Obj_06_TTC	54	BV2_Obj_06_PositionX
55	BV2_Obj_06_PositionY	56	BV2_Obj_07_Klasse
57	BV2_Obj_07_GeschwY	58	BV2_Obj_07_GeschwX
59	BV2_Obj_07_RadialDist	60	BV2_Obj_07_TTC
61	BV2_Obj_07_PositionX	62	BV2_Obj_07_PositionY
63	BV2_Obj_08_Klasse	64	BV2_Obj_08_GeschwY
65	BV2_Obj_08_GeschwX	66	BV2_Obj_08_RadialDist
67	BV2_Obj_08_TTC	68	BV2_Obj_08_PositionX
69	BV2_Obj_08_PositionY	70	BV2_Obj_09_Klasse
71	BV2_Obj_09_GeschwY	72	BV2_Obj_09_GeschwX
73	BV2_Obj_09_RadialDist	74	BV2_Obj_09_TTC
75	BV2_Obj_09_PositionX	76	BV2_Obj_09_PositionY
77	<b>BV2_Obj_10_Klasse</b>	78	BV2_Obj_10_GeschwY
79	BV2_Obj_10_GeschwX	80	BV2_Obj_10_RadialDist
81	<b>BV2_Obj_10_TTC</b>	82	BV2_Obj_10_PositionX
83	BV2_Obj_10_PositionY	<b>84 VZE_Verkehrszeichen_1</b>	
85	VZE_Verkehrszeichen_2	86	VZE_Verkehrszeichen_3
87	VZE_Verkehrszeichen_4	88	VZE_Verkehrszeichen_5
89	VZE_Verkehrszeichen_6	<b>90 SARA_Accel_X_b</b>	
91	<b>SARA_Accel_Y_b</b>		

### B.3. BESTIMMUNG DER GEEIGNETEN LÄNGE EINER REFERENZSTRECKE

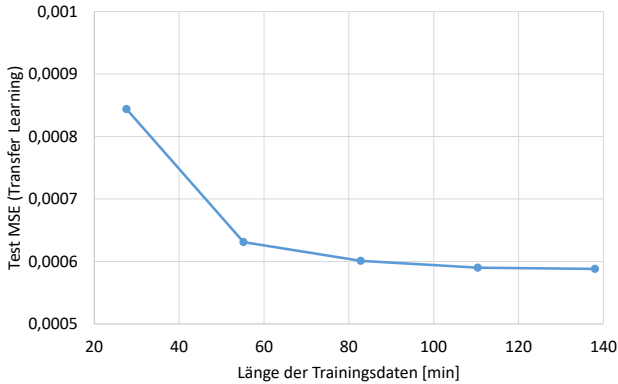


Abbildung B.1.: Bestimmung der optimalen Länge der Referenzstrecke, nach [185]

### B.4. VERGLEICH VERSCHIEDENER NETZWERKARCHITEKTUREN FÜR DAS RNN DER FAHRERINTENTIONSERKENNUNG

Nachfolgend werden verschiedene RNNs und deren Architekturen gegenübergestellt. Nach einer ersten Vorauswahl werden die Netzwerke 12, 57, 60 und 72 mit Hilfe unterschiedlicher CVs und zwei verschiedener Datensätze genauer untersucht. Eine Betrachtung mittels CV ist wichtig, da die Aufteilung des Datensatzes den größten Einfluss auf die MSE des Algorithmus hat. So kann ausgeschlossen werden, dass eine Architektur ausschließlich mit einer Datensatzaufteilung gute Ergebnisse aufweist. Die Architektur 72 zeigt im Vergleich mit den anderen RNN-Netzwerken stets die niedrigste MSE. Nähere Auswertungen werden von Höß und Schleyer beschrieben [182][183].

WEITERE ERGEBNISSE ZUR FAHRERINTENTIONSERKENNUNG

ID	MSE [10E-2]	LSTM #	LSTM Dimensionen	Eingänge der Ausgangsschicht	FC #	FC Dimensionen	Batchsize	Kostenf.
1	1,25	3	128-128-64	LSTM 3	1	25	500	MSE
2	1,23	3	128-128-64	LSTM 3	1	25	200	MSE
3	1,28	4	128-128-64-64	LSTM 4	1	25	500	MSE
4	1,39	4	128-128-64-64	LSTM 4	1	25	100	MSE
5	1,21	4	128-128-64-64	LSTM 4	1	25	100	MSE
6	1,22	3	128-128-64	LSTM 3	1	25	500	MSE
7	1,19	3	128-128-64	LSTM 3	1	25	500	MSE
8	1,28	2	128-128	LSTM 2	1	25	500	MSE
9	1,36	1	128	LSTM 1	1	25	500	MSE
10	1,56	3	128-128-64	LSTM 3	1	25	500	MSE
11	2,00	3	128-128-64	LSTM 3	1	25	500	MSE
12	1,91	3	128-128-64	LSTM 3	1	25	500	MSE
13	1,84	4	128-128-64-64	LSTM 4	1	25	500	MSE
14	2,08	4	128-128-64-64	LSTM 4	1	25	500	MSE
15	2,07	4	128-128-64-64	LSTM 4	1	25	500	MSE
16	1,99	4	128-128-64-64	LSTM 4	1	25	500	MSE
17	1,91	4	128-128-64-64	LSTM 4	1	25	500	MSE
18	2,00	3	128-128-64	LSTM 3	1	25	500	MSE
19	2,00	3	128-128-64	LSTM 3	1	25	500	MSE
20	1,91	3	128-128-64	LSTM 1-3	2	Sig128-25	500	MSE
21	1,93	3	128-128-64	LSTM 1-3	2	Sig128-25	500	MSE
22	1,88	4	128-128-64-64	LSTM 1-4	2	Sig128-25	500	MSE
23	1,90	4	128-128-64-64	LSTM 1-4	2	Sig128-Sig25	500	MSE
24	1,93	4	128-128-64-64	LSTM 1-4	2	Sig128-Sig25	500	MSE
25	1,90	4	128-128-64-64	LSTM 1-4	2	Sig128-Sig25	500	MSE
26	1,88	4	128-128-64-64	LSTM 1-4	2	ReLu128-Sig25	500	MSE
27	1,90	4	128-128-64-64	LSTM 1-4	3	ReLu128-Sig25	500	MSE
28	1,96	4	128-128-64-64	LSTM 1-4	3	ReLu128-Sig25	500	MSE
29	1,90	4	128-128-64-64	LSTM 1-4	3	ReLu128-Sig25	500	MSE
30	1,92	3	128-128-64	LSTM 1-3	3	ReLu128-Sig25	500	MSE
31	2,01	3	128-128-64	LSTM 1-3	3	ReLu128-Sig25	500	MSE
32	1,92	3	128-128-64	LSTM 1-3	3	ReLu128-Sig25	500	MSE
33	2,00	3	128-128-64	LSTM 1-3	3	ReLu128-Sig25	500	MSE
34	1,52	3	128-128-64	LSTM 1-3	3	ReLu128-Sig25	500	MSE
35	1,90	3	128-128-64	LSTM 1-3	3	ReLu128-Sig25	500	MSE
36	2,00	3	128-128-64	LSTM 1-3	3	ReLu128-Sig25	500	MSE

VERGLEICH VERSCHIEDENER NETZWERKARCHITEKTUREN FÜR DAS RNN  
DER FAHRERINTENTIONSERKENNUNG

---

37	1,78	3	128-128-64	LSTM 1-3	3	Relu128- ReLu128-Sig25	500	MSE
38	1,75	3	128-128-64	LSTM 1-3	3	Relu128- ReLu128-Sig25	500	MSE
39	1,84	4	128-128-64- 64	LSTM 1-4	3	Relu128- ReLu128-Sig25	500	MSE
40	1,81	4	128-128-64- 64	LSTM 1-4	3	Relu128- ReLu128-Sig25	500	MSE
41	1,88	3	128-128-64	LSTM 1-3	3	Relu128- ReLu128-Sig25	500	MSE
42	1,84	3	128-128-64	LSTM 1-3	3	Relu128- ReLu128-Sig25	500	MSE
43	1,79	3	128-128-64	LSTM 1-3	3	Relu128- ReLu128-Sig25	500	MSE
44	1,80	3	128-128-64	LSTM 1-3	2	ReLu128-Sig25	500	MSE
45	1,80	3	64-64-32	LSTM 1-3	2	ReLu128-Sig25	500	MSE
46	1,84	3	64-64-32	LSTM 1-3	2	ReLu64-Sig25	500	MSE
47	1,84	4	64-64-32-32	LSTM 1-4	2	ReLu64-Sig25	500	MSE
48	1,78	4	64-64-32-32	LSTM 1-4	2	ReLu128-Sig25	500	MSE
49	1,89	4	64-64-32-32	LSTM 1-4	2	ReLu128-Sig25	500	MSE
50	1,77	4	64-64-32-32	LSTM 1-4	3	Sig128- ReLu128-Sig25	500	MSE
51	2,55	4	32-32-32-32	LSTM 1-4	3	Sig128- ReLu128-Sig25	500	MSE
52	1,77	4	64-64-64-64	LSTM 1-4	3	Sig128- ReLu128-Sig25	500	MSE
53	1,79	4	128-64-32-32	LSTM 1-4	3	Sig128- ReLu128-Sig25	500	MSE
54	1,75	4	64-64-32-32	LSTM 1-4	4	Sig128- ReLu128-Sig25	500	MSE
55	1,81	3	64-64-64	LSTM 1-3	3	Sig128- ReLu128-Sig25	500	MSE
56	1,78	3	64-64-64	LSTM 1-3	3	Sig128- ReLu128-Sig25	500	MSE
57	1,78	4	64-64-64-64	LSTM 1-4	3	Sig128- ReLu128-Sig25	500	MSE
58	5,35	4	64-64-64-64	LSTM 1-4, in	3	Sig128- ReLu128-Sig25	500	MSE
59	2,06	4	64-64-64-64	in	1	Sig25	500	MSE
60	1,96	4	64-64-64-64	LSTM 1-4, in	3	Sig128- ReLu128-Sig25	500	MSE
61	1,80	4	64-64-64-64	LSTM 1-4, in	4	Sig128- ReLu128-Sig64- Bias25	500	MSE
62	9,12	4	64-64-64-64	LSTM 1-4, in	4	Sig128- ReLu128-Sig64- ReLu25	500	MSE
63	1,86	3	64-64-64	LSTM 1-3, in	4	Sig128- ReLu128-Sig64- Bias25	500	MSE
64	3,04	4	64-64-64-64	LSTM 1-4, in	3	ReLu128- Sig128-Sig25	500	MSE
65	1,82	4	64-64-64-64	LSTM 4	1	Sig25	500	MSE
66	1,86	4	64-64-64-64	LSTM 4	1	ReLu25	500	MSE
67	1,76	4	64-64-64-64	LSTM 3	1	Sig25	500	MSE
68	1,80	4	64-64-64-64	LSTM 3-4	1	Sig25	500	MSE
69	1,78	4	64-64-64-64	LSTM 3-4	1	Sig25	500	MSE
70	1,77	4	64-64-64-64	LSTM 3	1	Sig25	500	LogLoss
71	1,78	4	64-64-64-64	LSTM 2-4	2	Sig128-Sig25	500	LogLoss

---

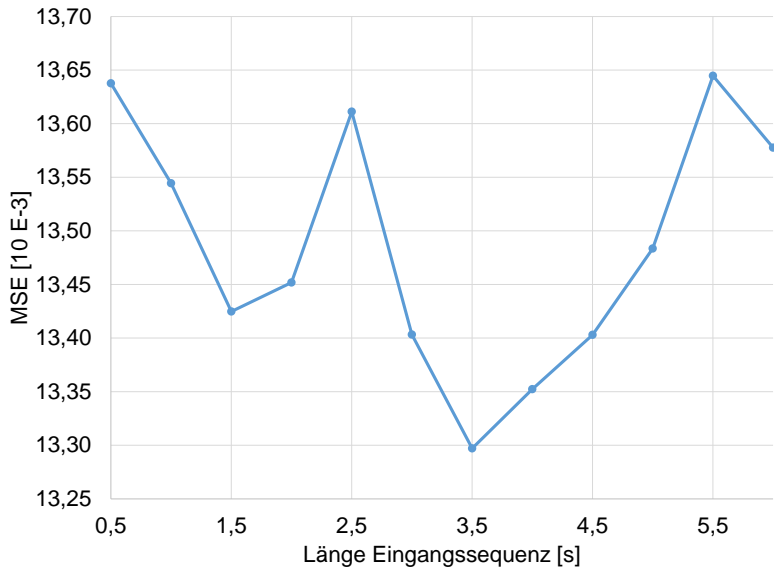
## WEITERE ERGEBNISSE ZUR FAHRERINTENTIONSERKENNUNG

---

72	1,77	4	64-64-64-64	LSTM 1-4, in	2	Sig128-Sig25	500	LogLoss
73	1,79	4	64-64-64-64	LSTM 1-4, in	2	Sig64-Sig25	500	LogLoss
74	1,81	4	64-64-64-64	LSTM 1-4, in	2	Sig256-Sig25	500	LogLoss
75	1,81	4	64-64-64-64	LSTM 1-4, in	3	Sig128-Sig64- Sig25	500	LogLoss



## B.5. BESTIMMUNG DER LÄNGE FÜR DIE EINGANGSSEQUENZEN DER FAHRERINTENTIONSERKENNUNG



**Abbildung B.2.:** Bestimmung einer optimalen Sequenzlänge für die Eingänge  
des RNN, nach [182]

---

## C VERÖFFENTLICHUNGEN

J. Reschke, S. Berlitz, und C. Neumann, „Personalised neural networks for a driver intention prediction: communication as enabler for automated driving,“ in *Advanced Optical Technologies*, M. Pfeffer, Ed. Berlin: DeGruyter, 2020.

J. Reschke, P. Mathea, S. Berlitz, W. Huhn, und C. Brockmeier, „Understanding Vehicle to Pedestrian Communication: Intuitivity and Learnability,“ in *8th International Forum on Automotive Lighting*, Shanghai, China, 2020, S. 75-82.

J. Reschke, T. Höß, B. Schleyer, S. Berlitz, und C. Neumann, „How Vehicles Learn to Display Symbols to Pedestrians,“ in *Proceedings of the 13th International Symposium on Automotive Lighting*, ser. Darmstädter Lichttechnik, T. Q. Khanh, Ed. München: utzverlag, 2019, S. 590-599.

J. Reschke, M.-T. Auburger, R. Marichalar, und C. Neumann, „Kommunikation zwischen automatisierten Fahrzeugen und Fußgängern,“ in *ATZ - Automobiltechnische Zeitschrift*, Bd. 121, no. 9, S. 16-21, 2019.

J. Reschke, S. Berlitz, M. Hamm, und W. Huhn, „Communication: Key Capability for the Acceptance of Automated Vehicles,“ in *7th International Forum on Automotive Lighting*, Shanghai, China, 2019, S. 27-32.

J. Reschke, S. Prösl, M. Hamm, und C. Neumann, „Assistance System for Vehicle-Pedestrian-Interaction: Deep Learning and Driver Intention Prediction,“ in *SIA VISION 2018: Proceedings*, SIA - French Society of Automotive Engineers, Ed., Paris, Frankreich, 2018, S. 19-26.

J. Reschke, P. Rabenau, M. Hamm, und C. Neumann, „Symbolische Fahrzeug-Fußgänger-Interaktion,“ in *Optische Technologien in der Fahrzeugtechnik*, VDI Wissensforum GmbH, Ed. Düsseldorf: VDI Verlag GmbH, 2018, S. 95-106.

W. Huhn, M. Hamm, und J. Reschke, „Digitales Licht für Fahrzeuge: Von Matrix-LED-Licht über DMD-Scheinwerfer bis zur OLED-Matrixheckleuchte,“ in *AUTOMOBIL-ELEKTRONIK*, Ed. Hüthig GmbH, 2018, S. 64-67

M. Hamm, W. Huhn, und J. Reschke, „Ideas for Next Lighting Generations in Digitalization and Autonomous Driving: Technical Paper 2018-01-1038,“ in *World Congress Experience*, SAE International, Ed., Detroit, USA, 2018.

---



---

## D BETREUTE ARBEITEN

N. Attia, „Driver Intention Prediction Using Deep Neural Networks,“ Master Thesis, Technische Universität München, München, 2020.

P. M. Mathea, „Aufbau und Evaluation eines intuitiven, kommunikationslicht-basierten Konzepts zur Fahrzeug-Fußgänger-Kommunikation im urbanen Raum,“ Master Thesis, Institut für Kraftfahrzeuge, RWTH Aachen, Aachen, 2019.

B. Schleyer, „Fahrerintentionserkennung an Fußgängerüberwegen - Implementierung eines Machine-Learning Ansatzes mit Personalisierung und Adaption auf fahrerspezifische Verhaltensweisen,“ Master Thesis, Fachhochschule Würzburg-Schweinfurt, Würzburg-Schweinfurt, 2019.

R. Marichalar Quezada und M.-T. Auburger, „Evaluation of Symbol and Color Comprehension in Vehicle-to-Pedestrian Communication for Autonomous Vehicles: An Online Survey on an Innovative Use of Headlights,“ Project Study, Chair of Marketing, Technische Universität München, München, 2019.

T. Höß, „Driver Intention Prediction at Pedestrian Crossings: Development, Implementation and Validation of different Approaches,“ Master Thesis, Informatik, Knowledge Engineering Group, Technische Universität Darmstadt, Darmstadt, 2019.

R. Ellouze, „Driver Intention Recognition based on Camera Data,“ Bachelor Thesis, Media Technology, Technische Universität München, München, 2018.

S. Prösl, „Deep Learning zur Erkennung der Fahrerintention an Fußgängerüberwegen für ein Lichtassistenzsystem,“ Master Thesis, Hochschule Kempten, Kempten, 2018.

---