

Technische Universität München

TUM School of Engineering and Design

**Konzeption und Langzeittest der  
Mensch-Maschine-Schnittstelle für die Teleoperation  
von automatisierten Fahrzeugen**

Jean-Michael Georg, M.Sc.

Vollständiger Abdruck der von der TUM School of Engineering and Design der  
Technischen Universität München zur Erlangung eines

**Doktors der Ingenieurwissenschaften (Dr.-Ing.)**

genehmigten Dissertation.

Vorsitz:

Prof. Dr. phil. Klaus Bengler

Prüfende der Dissertation:

1. Prof. Dr.-Ing. Markus Lienkamp

2. Prof. Dr.-Ing. Eckehard Steinbach

Die Dissertation wurde am 27.02.2024 bei der Technischen Universität München eingereicht  
und durch die TUM School of Engineering and Design am 27.05.2024 angenommen.



# Inhaltsverzeichnis

<b>Abkürzungsverzeichnis</b> .....	<b>V</b>
<b>1 Einleitung und Motivation</b> .....	<b>1</b>
<b>1.1 Problemstellung und Zielsetzung</b> .....	<b>3</b>
<b>1.2 Aufbau der Arbeit</b> .....	<b>3</b>
<b>2 Stand der Wissenschaft</b> .....	<b>5</b>
<b>2.1 Fahrzeuge</b> .....	<b>5</b>
2.1.1 Klassifizierung der Automatisierung und Teleoperation .....	5
2.1.2 Randfälle und Risikominimaler Zustand .....	6
2.1.3 Grundlegende Architektur .....	8
2.1.4 Sensoren zur Umgebungswahrnehmung .....	8
2.1.5 Auswahl geeigneter Sensoren für die Teleoperation .....	11
2.1.6 Sensorsetups in Fahrzeugen der Level 4 und 5 .....	12
<b>2.2 Teleoperation</b> .....	<b>13</b>
2.2.1 Kommunikationsverbindung .....	14
2.2.2 Steuerungsarten / Paradigmen der Teleoperation .....	15
2.2.3 Benutzerschnittstelle / HMI .....	16
2.2.4 Der menschliche Operator .....	22
<b>3 Ableitung der Forschungsfragen aus dem Stand der Wissenschaft</b> .....	<b>27</b>
<b>3.1 Zusammenfassung des Forschungsstands</b> .....	<b>27</b>
<b>3.2 Eingrenzung des Themas und Formulierung der Forschungsfragen</b> .....	<b>29</b>
<b>4 Methodik</b> .....	<b>31</b>
<b>4.1 Übergeordnete Makromethode</b> .....	<b>31</b>
<b>4.2 Anwendung der Methodik zur Beantwortung der Forschungsfragen</b> .....	<b>31</b>
<b>5 Vorgehen</b> .....	<b>35</b>
<b>5.1 Voranalyse</b> .....	<b>35</b>
5.1.1 Ziele .....	35
5.1.2 Probanden .....	35
5.1.3 Versuchsaufbau und Durchführung .....	36

5.1.4	Ergebnisse.....	38
<b>5.2</b>	<b>Entwicklung des HMI.....</b>	<b>39</b>
5.2.1	Ermittlung der Anforderungen .....	39
5.2.2	Umsetzung HMI .....	41
5.2.3	Videodatenvisualisierung .....	43
5.2.4	LiDAR-Daten Visualisierung.....	49
<b>6</b>	<b>Ergebnisse .....</b>	<b>53</b>
<b>6.1</b>	<b>Design Studie 1: Situationsbewusstsein, Anzeigeräte und Darstellungsformen .....</b>	<b>53</b>
6.1.1	Forschungsziele der Studie .....	53
6.1.2	Studienaufbau .....	54
<b>6.2</b>	<b>Auswertung Studie 1: Situationsbewusstsein, Anzeigeräte und Darstellungsformen.....</b>	<b>60</b>
6.2.1	A. Wahrnehmung Verkehrsteilnehmer .....	61
6.2.2	B. Wahrnehmung Verkehrsschilder.....	63
6.2.3	C. Schätzung der Geschwindigkeit .....	64
6.2.4	D. Schätzung der Spur.....	67
6.2.5	E. Vorhersage .....	69
6.2.6	F. Usability .....	71
6.2.7	G. Workload .....	73
6.2.8	H. Immersion.....	75
6.2.9	I. Sicherheitsgefühl .....	76
6.2.10	Direkter Vergleich .....	79
6.2.11	Zusammenfassung und Diskussion .....	80
<b>6.3</b>	<b>Design Studie 2: Präzise Steuerung .....</b>	<b>85</b>
6.3.1	Forschungsziel der Studie .....	85
6.3.2	Studienaufbau .....	85
<b>6.4</b>	<b>Auswertung Studie 2: Präzise Steuerung .....</b>	<b>87</b>
6.4.1	Abstand zu seitlichen Hindernissen .....	87
6.4.2	Abstand zwischen zwei Hindernissen .....	89
6.4.3	Abstand zu Haltelinien .....	89
6.4.4	Subjektive Bewertungsfaktoren.....	90
6.4.5	Zusammenfassung und Diskussion .....	91
<b>7</b>	<b>Diskussion und Ausblick .....</b>	<b>95</b>
<b>7.1</b>	<b>Übertragbarkeit auf andere Steuerungskonzepte .....</b>	<b>95</b>

<b>7.2 Berufsoperatoren .....</b>	<b>95</b>
<b>7.3 Übertragung weiterer Sensormodalitäten .....</b>	<b>96</b>
<b>7.4 Entwicklungsstand von HMD.....</b>	<b>96</b>
<b>8 Zusammenfassung .....</b>	<b>97</b>
<b>Abbildungsverzeichnis.....</b>	<b>i</b>
<b>Tabellenverzeichnis .....</b>	<b>v</b>
<b>Literaturverzeichnis .....</b>	<b>vii</b>
<b>Anhang .....</b>	<b>xxxiii</b>



# Abkürzungsverzeichnis

ADS	Automated Driving System
CLMM	Cumulative Link Mixed Effect Model
DFA	Dynamische Fahraufgabe
FOV	Field of View
GLMM	Generalized Linear Mixed Effect Model
HAF	Hochautomatisierte Fahrzeuge
HFOV	Horizontal Field of View
HMD	Head-Mounted-Display
HMI	Human-Machine-Interface
LiDAR	Light Detection And Ranging
LMM	Linear Mixed Effect Model
LOMM	Logistical Mixed Effect Model
ODD	Operating Design Domain
RA	Remote Assistance
RD	Remote Driving
RM	Remote Monitoring
RO	Remote Operator
ROS	Robot-Operating-System
VFOV	Vertical Field of View





# 1 Einleitung und Motivation

Der erste Schritt in der Industrialisierung war es, den Menschen durch technische Lösungen bei seiner Arbeit zunehmend zu unterstützen [1]. Im nächsten Schritt ist das Ziel, den Menschen nicht nur zu unterstützen, sondern komplett durch Maschinen zu ersetzen [2, S. 162]. Durch die Fortschritte auf dem Gebiet der Robotik, künstlicher Intelligenz und der besseren Verfügbarkeit von Rechenleistung ist es möglich, immer mehr Bereiche zu automatisieren und den Menschen nach und nach obsolet zu machen [3, S. 9]. Eines der Gebiete, indem diese Bestrebung derzeit Einzug hält, ist das Fahren auf öffentlichen Straßen. Während das automatisierte Fahren auf abgeschlossenen Geländen bereits möglich ist [4], stellt das automatisierte Fahren auf öffentlichen Straßen weiterhin eine Herausforderung dar. Die Begründung hierfür liegt in der Unkontrollierbarkeit aller zu einer Fahrsituation gehörenden Eigenschaften und der sich daraus ergebenden Komplexität, die um einige Faktoren größer ist als das Fahren auf einem abgeschlossenen und kontrollierbaren Gelände. Dieser Komplexität wird entgegengewirkt, indem zuerst die Automatisierung für Untergebiete des öffentlichen Raums entwickelt wird, in denen die Komplexität beherrschbarer ist. In den letzten Jahren haben sich im öffentlichen Bereich zwei Hauptanwendungsfälle herauskristallisiert. Der erste Anwendungsfall ist die Automatisierung als Assistenzfunktion für längere Fahrten auf der Autobahn, die hauptsächlich von Automobilkonzernen vorangetrieben wird, um den derzeitigen Kunden neue Funktionen anbieten zu können. Trotz der erhöhten Geschwindigkeit ist die mögliche Anzahl an Fahrszenarien aufgrund nicht vorhandener Fußgänger, einer eindeutigen Fahrtrichtung und einfacher Regeln begrenzt. Das reduziert die Komplexität bei der Entwicklung einer automatisierten Funktion. Dennoch erfordern die meisten Systeme derzeit eine Überwachung der Automatisierung durch den Menschen während der Fahrt. Mercedes ist der erste Automobilhersteller, der eine automatisierte Funktion anbietet, die nicht vom Fahrer überwacht werden muss. Diese ist jedoch nur bis 60 km/h bei Tageslicht und nicht bei Regen auf der Autobahn aktivierbar [5]. Eine mögliche Erklärung hierfür ist, dass die Anzahl an potenziellen Fahrszenarien zwar begrenzt ist, die Folgen bei einem Versagen des Systems aufgrund der erhöhten Geschwindigkeit jedoch eine größere Wahrscheinlichkeit haben, in einem schwerwiegenden Unfall zu enden. Im Kontext dieser Entwicklungen ist auch die Ankündigung von BMW relevant, die den Serienstart einer vergleichbaren Funktion plant, mit dem Unterschied, dass diese auch während der Dunkelheit verfügbar sein soll, was eine signifikante Erweiterung der Anwendungsbereiche impliziert [6].

Der zweite Anwendungsfall fokussiert sich auf den automatisierten Shuttle- oder Taxibetrieb in der Innenstadt, der hauptsächlich von Softwareunternehmen getrieben wird [7–9]. In diesem Anwendungsfall ist die Fahrzeuggeschwindigkeit deutlich geringer, jedoch sind die Komplexität und die Anzahl an möglichen Fahrszenarien aufgrund der gestiegenen Anzahl an relevanten Verkehrsteilnehmern höher als auf der Autobahn [10]. Generell sind die Systeme in diesem Anwendungsfall weiter entwickelt und werden bereits von einigen Unternehmen in Umgebungen mit geringer Komplexität fahrerlos erprobt [11–13]. Obwohl diese Systeme zumeist fehlerfrei funktionieren, entstehen dennoch Situationen, die das System nicht alleine bewältigen kann und ein Mensch eingreifen und die Maschine unterstützen muss [14, 15]. Die Häufigkeit dieser

Eingriffe muss in einigen Testgebieten veröffentlicht werden. So veröffentlicht der Bundesstaat Kalifornien jährlich die Disengagement Reports, in denen Betreiber von automatisierten Fahrzeugen dazu verpflichtet sind, jeden Eingriff, sei es durch Menschen (wie Sicherheitsfahrer, Remote-Operatoren oder Passagiere) oder durch das automatisierte Fahrzeugsystem selbst ausgelöst, in die automatisierte Funktion zu dokumentieren. Aus diesem Report lässt sich einerseits erkennen, welcher Betreiber das System hat, das am wenigsten menschliche Unterstützung benötigt, andererseits aber auch, dass die Automatisierung auch in Zukunft niemals alle Situationen alleine bewältigen können wird [16].

Während im ersten Anwendungsfall zunächst immer ein fahrfähiger Mensch im Fahrzeug ist, um die Fahrt am Ende der Operating Design Domain (ODD) zu übernehmen und um solche Situationen lösen zu können, kann im zweiten Anwendungsfall nicht davon ausgegangen werden. Eine mögliche Lösung für dieses Problem ist, dass ein Mensch sich aus der Ferne mit dem Fahrzeug z. B. über das Mobilfunknetz verbindet und die Situation auf Basis der vom Fahrzeug bereitgestellten Daten löst. Die Grundlagen dieser Technologie wurden bereits in anderen Anwendungsgebieten entwickelt und liegen in einem Unterbereich der Robotik, der Teleoperation. Die Teleoperation beschreibt die Steuerung von technischen Systemen aus der Ferne durch den Menschen, der in diesem Kontext Teleoperator oder Remote Operator (RO) genannt wird [17, S. 741].

Aufgrund der Notwendigkeit dieser Rückfallebene wird die Teleoperation auch als Schlüsseltechnologie für automatisierte Fahrzeuge gesehen [18]. Um eine effiziente Teleoperation zu gewährleisten, muss sichergestellt werden, dass der Operator alle für die derzeitige Fahraufgabe relevanten Informationen wahrnehmen kann. Neben den konventionellen Sensordaten wie z. B. Fahrzeuggeschwindigkeit und Gang werden insbesondere Kamera, LiDAR, Radar und Ultraschallsensoren für die Umgebungswahrnehmung und Detektion von Verkehrsteilnehmern und anderen für die Fahraufgabe relevanten Objekten verwendet. Während der Teleoperation sind insbesondere die Kameradaten von wichtiger Bedeutung. Diese ersetzen hierbei die Augen des Menschen im Fahrzeug und sind somit die wichtigste Quelle für die Wahrnehmung der Fahrzeugumgebung und anderer für die Fahraufgabe relevanter Informationen. Bei der praktischen Umsetzung ergeben sich aufgrund der elementaren Unterschiede zwischen einem biologischen Sehsinn und einem technischen Sensor technische Herausforderungen. So ist der menschliche Sehsinn einer konventionellen Kamera überlegen [19, S. 17]. Zusätzlich ergeben sich gegensätzliche Anforderungen aus dem Sensorlayout für Hochautomatisierte Fahrzeuge (HAF) und den Anforderungen für ein „ideales“ teleoperiertes System: Aufgrund der benötigten Rechenleistung werden Kameradaten in HAF mit weniger als 20 Hz verarbeitet, während für die Teleoperation aufgrund der geringeren Latenz eine höhere Frequenz vorteilhaft ist. Während ein konventionelles Sensorlayout für HAF eine Vielzahl von Kameras mit unterschiedlichen Blickrichtungen, Field of Views, Bildwiederholfräquenzen und Belichtungsmodi vorsieht, wäre im Gegensatz hierzu ein „ideales“ teleoperiertes System für den Operator nicht als System zwischen seinen Sinnen und der Fahrzeugumgebung wahrnehmbar, sondern komplett transparent. Der Operator würde nicht unterscheiden können, ob er sich an seiner realen Umgebung oder an der Fahrzeugumgebung befindet. Auf Basis der physikalischen Grundgesetze ist es nicht möglich, ein solches ideales System zu entwickeln. Dennoch forschen Unternehmen an Teleexistenzrobotern, die dieses Ziel verfolgen [20]. Hieraus lässt sich ableiten, dass die Wahrnehmung während der Teleoperation sich maßgeblich von der Wahrnehmung während einer realen Fahrt unterscheidet.

Die Aufgabe des Teleoperationssystems muss es folglich sein, dem Operator trotz der physikalischen Grenzen die Übersetzung der Sensordaten des Fahrzeugs in ein mentales Modell der Fahrzeugumgebung möglichst intuitiv und einfach zu ermöglichen. Kann dies nicht gewährleistet

werden, können sich hieraus schwerwiegende Folgen ergeben, weil gegebenenfalls Verkehrsteilnehmer oder andere wichtige relevante Informationen übersehen werden. Die Gestaltung des teleoperierten Systems hat folglich Auswirkungen auf die Sicherheit des Fahrzeugs im Betrieb. Neben anderen Komponenten in diesem System hat insbesondere die Schnittstelle zwischen dem System und dem Menschen, die auch als Human-Machine-Interface (HMI) bezeichnet wird, einen Einfluss auf die Umgebungswahrnehmung, weil die Gestaltung des HMI die Transferleistung von Sensordaten in ein mentales Modell maßgeblich erleichtern oder erschweren kann.

## 1.1 Problemstellung und Zielsetzung

Diese Arbeit beschäftigt sich daher mit der Fragestellung, wie das HMI für teleoperierte Automated Driving System (ADS) gestaltet sein sollte, um eine ausreichend gute Umgebungswahrnehmung bzw. ein ausreichend gutes Situationsbewusstsein während der Fahrt zu erreichen. Wichtig dabei ist, dass die fortlaufende Transferleistung eine mentale Belastung für den Operator bedeutet [21, S. 1]. Es reicht folglich nicht, nur die Umgebungswahrnehmung isoliert zu betrachten, sondern es muss auch sichergestellt werden, dass diese Aufgabe über einen längeren Zeitraum erfüllt werden kann. Daher muss das HMI nicht nur aus dem Blickwinkel der Sicherheit betrachtet werden, sondern es muss auch ergonomischen Ansprüchen genügen. Wie bereits erwähnt, ersetzen die im HAF verbauten Kameras die Augen des Menschen und dienen somit als primäre Quelle von Umgebungsinformationen. Durch die inhärenten Limitierungen moderner Kamerasensoren, zumindest im Vergleich mit dem menschlichen Sehsinn [19, S. 17], ergibt sich automatisch eine Reduzierung der aufgenommenen Informationen. So ist z. B. die Tiefenwahrnehmung durch ein einzelnes Bild eingeschränkt und Tiefeninformationen können nur durch monokulare Schätzmechanismen extrahiert werden [22]. Sieht der Operator z. B. kleine Fahrzeuge im Bild, wird auf eine weite Entfernung geschlossen. Für Fahrzeuge, die sich näher am Fahrzeug befinden, gestaltet es sich zunehmend schwieriger, die Entfernung der Kamera von dem Objekt richtig einzuschätzen, weil ein nahes Fahrzeug z. B. das ganze Bild einnehmen kann. Die genaue Bestimmung der Entfernung zu diesen nahen Objekten ist jedoch kritisch, um mögliche Kollisionen frühzeitig zu identifizieren und abzuwenden. Das HMI muss es schaffen, diesem Effekt entgegenzuwirken, um eine kollisionsfreie Fahrt gewährleisten zu können. Neben den Kameradaten sind in einem HAF andere Sensortechnologien wie LiDAR, Radar oder Ultraschall vorhanden, die für diese Aufgabe potenziell genutzt werden können. Diese Sensoren erfassen unter anderem auch Tiefeninformationen und ermöglichen es, die Entfernung von Objekten einzuschätzen. Es stellt sich die Frage, wie diese Sensoren in Kombination mit den Kameradaten genutzt werden können, um die Tiefenwahrnehmung des Operators zu verbessern. Zuletzt ist auch das Anzeigegerät an sich ein essenzieller Teil des Teleoperations-HMI. Die Entwicklung von Virtual-Reality-Systemen und Head-Mounted-Displays (HMD) eröffnet neue Möglichkeiten in der Darstellung der relevanten Sensoreinformationen.

## 1.2 Aufbau der Arbeit

In Abbildung 1.1 ist der Aufbau dieser Arbeit abgebildet. Im Anschluss an die Einleitung und Motivation folgt der Stand der Wissenschaft (Kapitel 2), der relevante Aspekte im Bereich hochautomatisierter Fahrzeuge und der Teleoperation beschreibt. Neben technischen Aspekten,

wie die verwendeten Sensoren für automatisierte Fahrzeuge, werden ergonomische Aspekte wie Immersion und Workload diskutiert.

Im Kapitel 3 und 4 werden die Forschungsfragen auf Basis des Stands der Wissenschaft abgeleitet und die Methodik zur Beantwortung der Fragen aufgestellt. Die anschließenden Kapitel beschreiben die Umsetzung der vorgestellten Methodik. Hierzu wird in Kapitel 5 im Rahmen einer Studie eine Voranalyse des bereits bestehenden Teleoperationssystems gewonnen und auf Basis der Erkenntnisse ein neues HMI entwickelt. Das entwickelte HMI wird in Kapitel 6 im Rahmen von zwei Probandenstudien verwendet, um die Forschungsfragen zu beantworten. In Kapitel 7 wird die Arbeit diskutiert und weitere relevante Forschungsgegenstände in Ausblick gestellt. Kapitel 8 fasst die Arbeit abschließend zusammen.

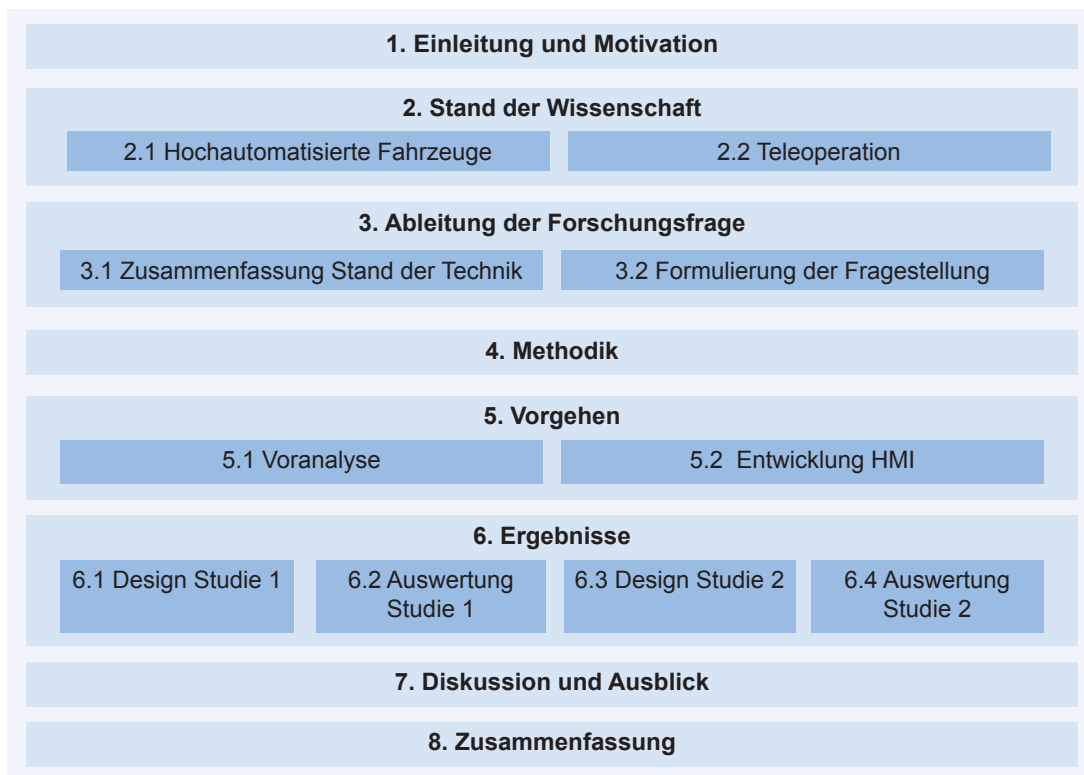


Abbildung 1.1: Übersicht über den Aufbau der Arbeit

## 2 Stand der Wissenschaft

Dieses Kapitel gibt eine Übersicht über den Stand der Technik und Wissenschaft im Bereich der hochautomatisierten Fahrzeuge und der Teleoperation. Es wird nur auf die für diese Arbeit relevanten Themengebiete eingegangen. Im Bereich der hochautomatisierten Fahrzeuge sind das neben einer kurzen Einführung in das Thema die Ursachen und Handhabung von Edge Cases sowie die Analyse von derzeitigen Sensoraufbauten. Im Bereich der Teleoperation werden bereits vorhandene Systeme vorgestellt und es wird auf den menschlichen Operator eingegangen.

### 2.1 Fahrzeuge

Die Bestrebung, Fahrzeuge für den öffentlichen Raum zu automatisieren bzw. fahrerlos zu machen, begann bereits 1925 mit dem ferngesteuerten „Houdina Radio Control“ [23]. Neben weiterer ähnlicher Prototypen waren vor allem die Aufgaben im Rahmen der DARPA Grand Challenges 2004–2007 ein Katalysator für die Entwicklung autonomer Fahrzeuge [4]. Während zunächst OEM die Forschung und Industrialisierung voranbrachten, wie der Audi TTS, der 2010 autonom den Pikes Peak befuhr [24], begann auch Google als erstes Softwareunternehmen 2009 mit der Entwicklung eines HAF und gründete 2014 die Tochterfirma Waymo [25].

#### 2.1.1 Klassifizierung der Automatisierung und Teleoperation

Im deutschen Raum wurden die Klassifizierungsmodelle zur Einordnung automatisierter Fahrzeuge von der Bundesanstalt für Straßenwesen (BASt) [26, S. 32] und dem Verband der deutschen Automobilindustrie (VDA) [27, S. 7] eingeführt. Im amerikanischen Raum wurde eine vergleichbare Klassifizierung von der National Highway Traffic Safety Administration (NHTSA) und der Society of Automotive Engineers (SAE) getroffen [28, S. 25]. Alle Schemata beruhen auf Stufen, die eine Kategorisierung der Fähigkeiten und Verantwortung von Fahrzeugsystemen bezüglich der Übernahme von Fahraufgaben ermöglichen. Eine höhere Stufe kennzeichnet eine höhere Automatisierung und einen geringeren Grad an erforderlicher menschlicher Intervention. Dies trägt zur Regulierung und Überwachung des Einsatzes von hochautomatisierten Fahrzeugen bei. Abbildung 2.1 gibt einen Überblick über die verschiedenen Klassifizierungsschemata.

Aufgrund der gleichen Bezeichnung für die Level 3 und 4 nach BASt/VDA und Level 4 und 5 nach SAE ist eine genaue Zuordnung des Funktionsumfangs eines HAF nur in Kombination mit der Nennung des verwendeten Klassifizierungsschemas möglich. Während die BASt und die SAE-Klassifizierung auf der Aufgabenteilung zwischen Mensch und Maschine beruhen, erweitert die VDA die verschiedenen Level um zusätzliche Anforderungen hinsichtlich der Interaktion von Mensch und Maschine, wie z. B. Reaktionszeiten und Rückfallebenen, die evtl. auf einen Teleoperator übertragbar sein könnten. In dieser Arbeit wird die Klassifizierung nach

SAE verwendet. Während in den Levels 0–3 ein menschlicher Fahrer für die Fahraufgabe verantwortlich ist, ist bei Level 4 und 5 ein Mensch im Fahrzeug optional.

Level	0	1	2	3	4	5
<b>SAE</b>	No Automation	Driver Assistance	Partial Automation	Conditional Automation	High Automation	Full Automation
<b>NHTSA</b>	No Automation	Function-specific Automation	Combined Function Automation	Limited Self-Driving Automation	Full Self Driving Automation	
<b>BASt</b>	Driver only	Driver Assistance	Partial Automation	High Automation	Full Automation	

Abbildung 2.1: Angenäherte Übereinstimmung zwischen SAE, BASt und NHTSA nach [29, S. 32]

Ein HAF (Level 4) kann in einem definierten Anwendungsfall und einer definierten Region ohne den menschlichen Fahrer im Fahrzeug die Fahraufgabe übernehmen. Ein Level 5 Fahrzeug ist zudem weder auf eine Region noch auf einen Anwendungsfall begrenzt. Bei beiden können „Edge Cases“ bzw. Randfälle auftreten, die nicht von der Maschine gelöst werden können, z. B. bei einem falsch detektierten Objekt oder einer falsch interpretierten Situation. Da kein Fahrer mehr im Fahrzeug vorhanden ist, um diese Edge Cases zu lösen, wäre das Fahrzeug an dem Ort, an dem der Fehler aufgetreten ist, betriebsunfähig. Die möglichen Optionen, das Fahrzeug wieder in Betrieb zu nehmen, sind: Entweder eine Person begibt sich zum Fahrzeug und behebt den Fehler vor Ort, oder eine Person verbindet sich über eine kabellose Verbindung und behebt die Fehlerursache aus der Ferne. Aufgrund der Tatsache, dass in Level 0–3 noch ein Fahrer im Fahrzeug vorhanden ist, um potenzielle Fehler zu beheben, liegt der Fokus dieser Arbeit auf der Handhabung von Randfällen für Fahrzeuge der Level 4 und 5.

Auch die SAE hat diesen Anwendungsfall identifiziert und definiert zusätzlich zu den Levels für das automatisierte Fahren weitere Rollen, die mit den HAF interagieren. So erweitert die neuste Revision [28] des Standards die vorherigen Revisionen [30] erstmalig um die Definition der „Remote Assistance“ (RA) [28, S. 18] und „Remote Driving“ (RD) [28, S. 19]. Auch in China ist seit März 2022 eine an die SAE angelehnte Klassifizierung in Kraft, die der Automatisierung eine größere Bedeutung zuordnet und erstmals einen „Fahrer aus der Ferne“ bzw. Teleoperator berücksichtigt [31]. Teleoperation wird somit als fester Bestandteil eines ADS gesehen. Bogdoll [32, S. 9] bemängelt die derzeitige Einordnung von ferngesteuerten Systemen im Kontext des hochautomatisierten Fahrens und geht einen Schritt weiter, indem er eine Taxonomie für „Remote Human Input System“ definiert und diese den einzelnen SAE-Levels zuweist (Abbildung 2.2). Hierbei nennt Bogdoll nicht nur Remote Driving und Remote Assistance, sondern auch „Remote Monitoring“ (RM) als mögliche Aufgabe des Operators. Zudem zeigt er auf, dass unterschiedliche RO-Aufgaben unterschiedliche HMI benötigen. Die einzelnen Level definieren weiterhin eine klare Aufgabenteilung zwischen dem RO und dem automatisierten System. Im Remote Driving trägt der RO die Verantwortung für die dynamische Fahraufgabe (DFA), während er bei der Remote Assistance nicht an der Fahraufgabe beteiligt ist, sondern dem automatisierten System hilfestellend agiert.

### 2.1.2 Randfälle und Risikominimaler Zustand

Kalifornien hat 2012 als einer der ersten Staaten das Betreiben und Testen von automatisierten Fahrzeugen im öffentlichen Raum unter gewissen Auflagen genehmigt. Seit 2014 muss ein Sicherheitsfahrer das Fahrzeug überwachen und alle Eingriffe und Übernahmen des Fahrers in

RHIS Level	0	1	2	3	4	5
Type	Remote Monitoring	Remote Driving		Remote Assistance		
SAE Level	- / 3	1 - 2		4 - 5		
Operator Aufgabe	Monitoring	DFA	DFA	Eingabe OEDR	Eingabe Strategische Funktionen	Authorisierung von Optionen
HAF Aufgabe	DFA	--	Safety Guard	DFA Rückfallebene	DFA, Rückfallebene	DFA, Rückfallebene, Optionen
HMI	Monitore	Monitore/HMD, Lenkrad, Pedale, Gangwahl		Monitore, Keyboard, Maus / Touch Input		

Abbildung 2.2: Taxonomie für Remote Human Input Systems nach Bogdoll et al. [32, S. 9]

Situationen, die das System nicht allein bewältigen kann, dokumentieren. Die Dokumentation dieser Eingriffe wird jährlich in den Disengagement Reports [33] veröffentlicht und erlaubt einen Überblick über den derzeitigen Entwicklungsstand der hochautomatisierten Systeme, die in Kalifornien getestet werden. Abbildung 2.3 zeigt die im Durchschnitt gefahrenen Meilen zwischen zwei Disengagements für das Jahr 2022, aufgliedert nach den Betreibern.




Abbildung 2.3: Links: Meilen Pro Disengagement für die Top-10 AV Firmen. Rechts: Entwicklung der Meilen pro Disengagement von 2015 bis 2022.

Bei diesen Fahrten ist der Auslöser der Disengagements der Sicherheitsfahrer, ein RO, ein Passagier oder das System selbst. Obwohl die gefahrenen Meilen zwischen zwei Disengagements über die Jahre exponentiell steigen, zeigt diese Statistik die Grenzen der Automatisierung auf. Auf Basis dessen muss davon ausgegangen werden, dass auch in Zukunft HAF Systemgrenzen erreichen werden und es zu Disengagements und unvorhergesehenen Fehlern während der gesamten Betriebszeit des Fahrzeugs kommt. Aufgrund des fehlenden Fahrzeugführers muss laut SAE ein „Fahrzeug des Levels 4 oder höher einen leistungskritischen Systemfehler“ [34] oder das „Erreichen einer Systemgrenze“ [34] selbstständig erkennen und selbstständig über eine Rückfallebene in einen risikominimalen Zustand gelangen. Dies unterscheidet sich von einem Level 3 System, bei dem der Fahrer die Rückfallebene darstellt. Der risikominimale Zustand ist allgemein nicht definiert, ist abhängig von der derzeitigen Fahrsituation und könnte

z. B. bedeuten, dass das Fahrzeug „auf den Seitenstreifen fährt, die Warnblinkanlage einschaltet, das Antriebssystem abschaltet oder anderweitige Hilfe ruft“ [28, S. 37].

Nach dem Erreichen des risikominimalen Zustands muss das System wieder in den normalen Fahrmodus überführt werden. Hierzu gibt es drei Optionen: Das System schafft es selbstständig die Ursache zu beheben, eine Person im Fahrzeug behebt den Fehler vor Ort oder ein RO verbindet sich mit dem Fahrzeug und behebt die Degradierung aus der Ferne. Die erste Option ist favorisiert, es kann aber nicht davon ausgegangen werden, dass diese immer möglich ist. Während bei der zweiten Option nicht davon ausgegangen werden kann, dass eine Person im Fahrzeug ist, bietet die dritte Option den Vorteil, überall dort verfügbar zu sein, sofern eine ausreichende mobile Datenverbindung vorhanden ist.

Der risikominimale Zustand ist im Zusammenhang mit Teleoperation in zwei Fällen relevant: Entweder wird Teleoperation eingesetzt, um zu verhindern, dass das Fahrzeug in diesen Zustand degradiert, indem der RO als Rückfallebene dient, oder das Fahrzeug befindet sich bereits in diesem Zustand und dient als Ausgangspunkt der Interaktion zwischen RO und HAF. In beiden Fällen muss der Operator zunächst über die übertragenen Fahrzeugsensordaten und Systeminformationen ein ausreichendes Umgebungs- und Systemverständnis aufbauen, um mögliche Ursachen für die Degradierung zu erkennen und die richtigen nächsten Schritte zu wählen. Je nach Zustand des HAF kann hierfür ein unterschiedliches „Remote Human Input System“ Level notwendig sein.

### 2.1.3 Grundlegende Architektur

Es existieren verschiedene Architekturen für ADS, die grundsätzlich in die Ansätze End-to-End-Learning [35–39] und Sense-Plan-Act [40, 41, 42, S. 10] eingeordnet werden können. Die Sense-Plan-Act-Architektur stammt ursprünglich aus der Robotik, findet aber aufgrund der modularen Aufgabenteilung und dadurch guten Absicherbarkeit Verwendung in HAF. Abbildung 2.4 zeigt die Implementierung der Sense-Plan-Act-Architektur von Autoware, einem Open-Source-Framework für HAF.

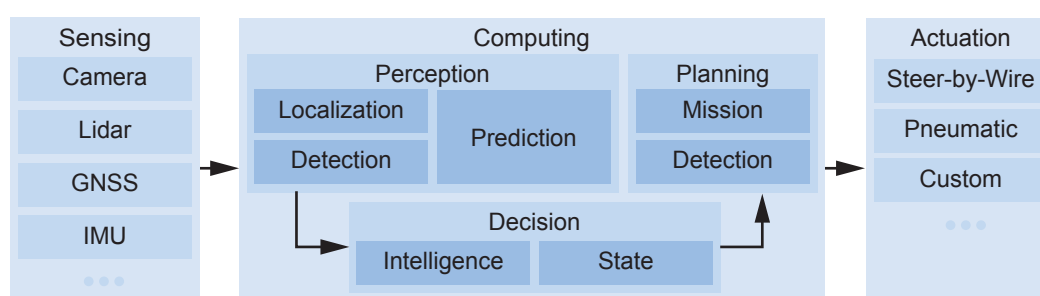


Abbildung 2.4: Sense-Plan-Act: Architekturübersicht nach Biggs [43]

### 2.1.4 Sensoren zur Umgebungswahrnehmung

Automatisierte Fahrzeuge verfügen neben vielen auch in konventionellen Fahrzeugen vorhandenen Sensoren, wie z. B. Lenkwinkel- oder Geschwindigkeitssensoren, vor allem über Sensoren für die Wahrnehmung der Umgebung des Fahrzeugs. Hierzu werden hauptsächlich Kamera, LiDAR, Radar und Ultraschallsensoren verwendet [44]. Vargas et al. [45] beschreiben die verschiedenen Sensorarten sowohl hinsichtlich der Funktionsweise als auch ihrer Vor- und Nachteile ausführlich. Da der Fokus dieser Arbeit auf Kamera- und LiDAR-Sensoren liegt, wird auf



deren Funktionsweise genauer eingegangen. Zudem wird auf die Positionierung der Sensoren am Fahrzeug und die jeweiligen Sichtbereiche eingegangen.

## Radar

Radarsensoren sind ein wichtiger Bestandteil der Fahrzeugtechnik, weil sie durch Übertragung von Radiowellen und Analyse der reflektierten Signale Entfernung, Geschwindigkeit und Richtung von Zielobjekten bestimmen können. Der Ursprung von Radar (Radio Detection and Ranging) liegt in der Militärtechnik. Im Straßenverkehr werden Frequenzen zwischen 24 GHz und 81 GHz verwendet, wobei sich 76,5 GHz als Standard etabliert haben. [46, S. 123]

Radar hat im Vergleich zu anderen Sensorsystemen einen besonderen Vorteil in Bezug auf seine Fähigkeit, den Dopplereffekt zu messen und zudem robust gegenüber ungünstigen Wetterbedingungen zu sein. Dennoch ermöglicht Radar nur eine geringe Raumauflösung bei einer akzeptablen Antennengröße. Das Field of View (FOV) von Radarsensoren reicht von geringen 30–45 Grad [47, S. 3] bis zu 90 Grad und mehr [48].

Ein Nachteil von Radarsensoren ist, dass diese eine Nachverarbeitung der Daten benötigen. Schumann et al. [49] präsentieren ein Datenset von realen aufgezeichneten Radar- und Kameradaten (Abbildung 2.5). Die Rekonstruktion der Szene rein auf Basis der Radardaten ist für den Menschen nur schwer intuitiv möglich. Das Betrachten der dazugehörigen Kameradaten erlaubt ein deutlich leichteres Verständnis der Fahrzeugumgebung.




Abbildung 2.5: Radar- und Kameradatenvisualisierung realer Szenen nach Schumann et al. [49, S. 4]

## Ultraschall

Ultraschallsensoren arbeiten auf der Grundlage der Übertragung von Schallwellen mit Frequenzen über 20 kHz bis 100 kHz [50, S.760], die deutlich höher sind als die vom menschlichen Gehör wahrnehmbaren Frequenzen zwischen 16 Hz und 20 kHz. Der Sendeempfänger sendet einen Ultraschallimpuls aus und misst die Zeit, die vergeht, bis ein Echo von einem Objekt im Bereich des Fahrzeugs empfangen wird. Aus der Zeitdifferenz und der bekannten Schallgeschwindigkeit kann die Entfernung des Objekts berechnet werden [51].

Diese Technologie bietet einige Vorteile, einschließlich einer hohen Genauigkeit bei der Messung von Entfernungen, einer schnellen Reaktionszeit und der Fähigkeit, Objekte zu erkennen, die für andere Sensortechnologien unsichtbar sind, wie zum Beispiel bei Nebel, Regen oder Dunkelheit. Ein Nachteil von Ultraschallsensoren ist, dass diese nur Objekte erkennen können, die in unmittelbarer Nähe des Fahrzeugs sind, was ihre Einsatzmöglichkeiten einschränkt. Darüber

hinaus können harte Oberflächen, wie zum Beispiel Beton, die Übertragung von Schallwellen stören und die Genauigkeit beeinträchtigen. [52]

Aufgrund der geringen Reichweite und der niedrigen Kosten finden Ultraschallsensoren in der Fahrzeugtechnik hauptsächlich Anwendung in Park- und Totwinkelassistenten, wo die Entfernungsmessung durch aufwendige algorithmische Signalverarbeitung in akustische Warnsignale und/oder optische Anzeigen der Fahrzeugumgebung umgerechnet werden [46, S. 122].

### **Kamera**

Kamerasensoren bestehen in der Regel aus zwei Einheiten: der Optik und dem Kamerachip. Die Optik besteht aus einem oder mehreren optischen Elementen und dient dazu, die Lichtstrahlen aus der dreidimensionalen Umgebung zu bündeln und auf den zweidimensionalen Imager zu projizieren. Der Imager ist ein Chip, der die durch die Optik gebündelten Photonen in elektrische Signale umwandelt. Dabei ist der Imager rasterförmig aufgebaut und besteht aus sogenannten Pixeln. Jeder Pixel ist sensitiv auf bestimmte Farben bzw. Wellenlängen. Durch die Summe aller Pixel ergibt sich eine zweidimensionale digitale Abbildung der Umgebung.

In der Fahrzeugtechnik werden Kameras hauptsächlich in zwei Wellenlängenbereichen eingesetzt:

- Kameras im infraroten Wellenlängenbereich, die sensitiv auf Wärmestrahlung sind und somit z. B. Objekte in kompletter Dunkelheit wahrnehmen können. Aufgrund des anderen Wellenlängenbereichs können Infrarotkameras keine Farben detektiert [45, S. 8]
- Kameras, die in einem ähnlichen Wellenlängenbereich wie das menschliche Auge arbeiten, erzeugen Ergebnisse, die leicht von einem Menschen interpretiert werden können. Als positiver Effekt ist hier der alltägliche Umgang von Menschen mit Kamerabildern anzumerken, der den intuitiven Umgang verstärkt.

In der Serienentwicklung von Fahrzeugen werden Kameras hauptsächlich für Fahrerassistenzfunktionen eingesetzt, wie z. B. Spurhalteassistenten, Verkehrsschilderkennung, Notbremsassistenten oder Systeme zur Verbesserung der Umgebungswahrnehmung des Fahrers, wie z. B. Rückfahrkameras oder komplette Top-View bzw. Surround-View-Systeme [53, S. 31]. Im Bereich der Forschung und Entwicklung spielen Kameras in Kombination mit modernen, auf neuronalen Netzwerken [54, S. 5] basierenden Bildverarbeitungsalgorithmen eine entscheidende Rolle bei der Entwicklung autonomer Systeme. Nicht nur können Objekte erkannt werden, sondern es können auch auf wenige Millimeter genaue Standortinformationen aus den Kameradaten gewonnen werden [55, S. 10]. Ein Grund hierfür ist die große Informationsdichte in einem Bild. Üblicherweise werden Sensoren zwischen 4 und 12 Megapixeln eingesetzt, die pro Pixel jeweils drei Farbwerte erzeugen. Zudem können Kameras durch die Auswahl verschiedener Optiken sowie die Einstellung verschiedener Parameter ohne großen Aufwand an den jeweiligen Anwendungsfall angepasst werden. Aufgrund dieser Faktoren ist die Kamera der wichtigste Sensor bei der Entwicklung autonomer Fahrzeuge und ist in allen Systemen für HAF vorhanden.

Weiterhin werden Stereokamerasysteme eingesetzt, um auf der Basis der binokularen Ungleichheit Tiefeninformationen aus den aufgenommenen Bildern zu gewinnen. Der Einsatz solcher Systeme geht jedoch aufgrund der Fortschritte in der Bildverarbeitung zurück. So ist die Berechnung von Tiefeninformationen z. B. mithilfe neuronaler Netzwerke auch auf Basis von Monokameradaten möglich [56].

## LiDAR

Light Detection and Ranging (LiDAR) ist eine Technologie, die es ermöglicht, Entfernungen und Geschwindigkeiten optisch zu erfassen und zu messen. Dies geschieht durch den Einsatz von Lasern, die Lichtimpulse aussenden und die Zeit bis zu deren Rückkehr („Time of Flight“) zum Detektor messen. Auf Basis der bekannten Lichtgeschwindigkeit und der gemessenen Zeitdifferenz kann der Abstand zum Objekt bestimmt werden. Die physikalischen Grundprinzipien des Systems ähneln dem Radar, verwenden allerdings Infrarot- oder Ultraviolett-Strahlen im Bereich von 850 nm bis 1  $\mu\text{m}$  anstelle von Mikrowellen. [46, S. 172]

LiDAR gibt es in verschiedenen Bauformen, die mit einem oder mehreren Lasern oder LEDs arbeiten und die mit oder ohne variablen Umlenkspiegel eingesetzt werden können. Die genaue Ausrichtung dieser Spiegeleinheiten und die Bestimmung der Entfernung eines jeden Punktes ermöglichen es, Messpunkte im Koordinatensystem des LiDAR genau zu bestimmen. Moderne LiDAR können mehrere Millionen Messpunkte pro Sekunde detektieren [57, 58]. Hierbei ist es durch die flexible Spiegelstellung möglich, 360°-Messungen auf verschiedenen Ebenen um den Sensor zu erstellen und somit detaillierte dreidimensionale Ansichten um den Sensor zu generieren [59]. Dies erlaubt es auch einem Menschen, prinzipiell die Sensordaten zu verstehen und Szenen mental rekonstruieren zu können (Abbildung 2.6).




Abbildung 2.6: Sensor datenausschnitt Ouster LiDAR OS1 [57]

Aufgrund des Wellenlängenbereichs in der Nähe des sichtbaren Lichts können Regen, Schnee oder Nebel die Funktionsweise beeinträchtigen. Weitere Nachteile sind die Verwendung von beweglichen Komponenten und der relativ hohe Preis, die eine weite Verbreitung in Serienfahrzeugen bisher ausgeschlossen haben. Obwohl die Datendichte hoch ist, ist die Frequenz mit 5 bis 25 Hz [44] verglichen mit anderen Sensorsystemen gering. Trotz dieser Nachteile haben sich LiDAR-Sensoren in allen Fahrzeugen der Level 4 oder höher aufgrund des großen Sichtbereichs, der hohen Datendichte und der dreidimensionalen Messmöglichkeit etabliert.

### 2.1.5 Auswahl geeigneter Sensoren für die Teleoperation

In dem vorherigen Kapitel wurden die grundlegenden Eigenschaften verschiedener für die Umgebungswahrnehmung eingesetzter Sensoren aufgezeigt. In diesem Kapitel werden die Sensoren hinsichtlich ihrer Eignung für die Teleoperation bewertet.

Abbildung 2.7 zeigt eine Zusammenfassung der für die Teleoperation relevanten Eigenschaften der in den vorherigen Kapiteln vorgestellten Sensortechnologien. Radar ist aufgrund der notwendigen aufwendigen Nachbearbeitung der Daten für die Teleoperation von Fahrzeugen nicht geeignet.

Bei Ultraschallsensoren sind die Reichweite und Auflösung gering. In der näheren Fahrzeugumgebung kann mit Ultraschall die Anwesenheit und Entfernung von Objekten festgestellt werden, jedoch können Objekte und deren Dimensionen nicht genau identifiziert werden. Zudem erlaubt die geringe Reichweite nur eine geringe Geschwindigkeit. Feig [60, S. 78] hat z. B. verschiedene Parkassistenten auf Basis von Ultraschallsensoren evaluiert und festgestellt, dass diese nur Kollisionen bis 3 km/h oder weniger verhindern können.

Kameradaten sind aufgrund der hohen Datendichte und Ähnlichkeit mit dem menschlichen Sehsinn am geeignetsten für die Teleoperation. Die fehlenden Tiefeninformationen und zweidimensionale Darstellung erschweren es dem RO jedoch, die Distanz zu Objekten einzuschätzen [61].

LiDAR-Daten haben eine hohe Reichweite, können vom Menschen interpretiert werden, besitzen eine hohe Dichte an Tiefeninformationen und sind Bestandteil von HAF. Eine Kombination aus LiDAR- und Kameradaten bietet sich als mögliches Anzeigekonzept an (siehe grüne Markierung in Abbildung 2.7).

	Reichweite	Interpretierbarkeit	Tiefeninformationen
Radar	+	-	+
Ultraschall	-	-	+
Kamera	+	+	-
Lidar	+	+	+

Abbildung 2.7: Übersicht unterschiedlicher Sensortypen in Hinblick auf Reichweite, menschliche Interpretierbarkeit und vorhandene Tiefeninformationen

### 2.1.6 Sensorsetups in Fahrzeugen der Level 4 und 5

Das vorherige Kapitel hat verschiedene Sensorarten vorgestellt. In hochautomatisierten Fahrzeugen werden mehrere Sensortypen parallel eingesetzt, weil die Sensorcharakteristiken zeigen, dass jeder Sensor nur bestimmte Eigenschaften der Umgebung wahrnehmen kann. Daher ist ein einzelner Sensor nicht ausreichend, um die Fahrzeugumgebung umfassend darzustellen [62, S. 14]. Dieses Vorgehen hat in der Regel zwei Hauptgründe. Einerseits werden Sensoren aufgrund ihrer jeweiligen Vor- und Nachteile kombiniert, um ihre Fähigkeiten zu ergänzen und somit eine höhere Zuverlässigkeit und Genauigkeit der Sensorik zu gewährleisten. Andererseits ergeben sich durch die Einführung redundanter Systemkomponenten weitere Möglichkeiten zur Absicherung gemäß der Norm ISO 26262 [63]. Die Einführung redundanter Systemkomponenten ist eine Möglichkeit, die Sicherheit und Zuverlässigkeit von Systemen zu erhöhen. Durch den Einsatz mehrerer Sensoren können Fehler oder Ausfälle einzelner Sensoren kompensiert und somit ein sicherer Betrieb des Fahrzeugs sichergestellt werden. Daher ist es üblich, dass Fahrzeuge der Stufe 4 oder höher Sensorsets verwenden, die mehrere Sensormodalitäten kombinieren. Abbildung 2.8 zeigt exemplarisch zwei verschiedene Sensorsets von Waymo und NuTonomy/Motional.

Die Sensorsets bestehen aus einer Vielzahl von verschiedenen Sensoren, die sowohl für den Nahbereich als auch für den Fernbereich eingesetzt werden. Beispielsweise verfügt das Dachmodul von Waymo über ein 360° LiDAR- und Kamerasystem, während Module an den Ecken des Fahrzeugs für die Abdeckung des Nahbereichs eingesetzt werden. Zusätzlich zur primären Funktion der Umgebungserfassung und -navigation stehen alle diese Sensordaten potenziell einem RO zur Verfügung. Aufgrund der Fülle der Informationen, die von den Sensoren



Abbildung 2.8: Sensorsetup verschiedener HAF. Links: Waymo [9]. Rechts: NuTonomy [64, S. 4].

erfasst werden, muss das HMI so gestaltet sein, dass der Operator nicht überfordert wird. So vermuten z. B. Mutzenich et al. [65, S. 14], dass die Anzeige mehrerer Kameras auf verschiedenen Monitoren eine größere Arbeitsbelastung für RO zur Folge hat.

## 2.2 Teleoperation

Wie bereits in den vorherigen Kapiteln erwähnt, ist für HAF in Situationen Unterstützung nötig, die entweder die Systemfähigkeiten überschreiten oder nicht allein vom System bewältigt werden können [66, S. 1]. Dies können z. B. auch simple Aufgaben wie das Öffnen von Türen oder das Antworten auf Passagieranfragen sein [67, S. 5]. Aus diesem Grund ist Teleoperation bereits Bestandteil verschiedener Lösungen für HAF [7, 68–78]. Wie aus Abbildung 2.9 hervorgeht ergänzen sich Teleoperation und HAF aufgrund ihrer jeweiligen Stärken und Schwächen. Nur in Kombination beider Technologien ist es möglich, ein System zu entwickeln, das alle Fahraufgaben bewältigen kann [78]. Dieser Zusammenhang wird durch die Anzahl an Patentanmeldungen im Bereich der Teleoperation in den letzten Jahren untermauert (Abbildung 2.9). Diese verdeutlichen das gestiegene Interesse an der Technologie und die damit verbundenen Potenziale. So zeigen Hampshire et al. [79, S. 5], dass der Einsatz eines RO in Kombination mit autonomen Fahren insgesamt 14.840 echte Fahrer ersetzen könnte.

In den letzten Jahren haben sich nicht nur Unternehmen auf die Entwicklung von autonomen Fahrzeugen spezialisiert, sondern es haben sich auch Unternehmen etabliert, die sich auf reine Teleoperation von Fahrzeugen auf öffentlichen Straßen sowie auf Privatgeländen fokussieren [80–83]. Dabei hat die Teleoperation ihren Ursprung in der Robotik und wird dort für Aufgaben eingesetzt, die weder von Menschen noch vom Roboter allein ausgeführt werden können [84, S.163]. Die Anwendungsfälle sind nahezu unbegrenzt und gehen von der Medizin- [85], Weltraum- [86], Nuklear- [87, 88], Militär- [89, 90] und Unterwassertechnik [91–93] bis zu Such-, Rettungs- [94–97], Service- [98, 99] und Überwachungsrobotern [100].




Abbildung 2.9: Links: Symbiose zwischen Teleoperation und HAF nach Tiwari [78]. Rechts: Anzahl der veröffentlichten Teleoperationspatente nach Majstorovic et al. [34].

Teleoperationssysteme sind in der Regel aus drei wesentlichen Komponenten zusammengesetzt: einer Benutzerschnittstelle, einer Kommunikationsverbindung und einem Roboter [101, S. 3]. Die Kommunikationsverbindung ermöglicht dabei den Austausch von Sensordaten zwischen dem Roboter und der Benutzerschnittstelle. Diese Daten werden üblicherweise durch visuelle oder haptische Anzeigen an den Menschen weitergegeben, der die Informationen interpretiert und mittels Eingabegeräten an der Benutzerschnittstelle über die Kommunikationsverbindung Befehle an den Roboter zurücksendet. Für diese Arbeit steht die Benutzerschnittstelle und insbesondere die Anzeige der Sensordaten im Vordergrund. Es wird in geringerem Umfang auf die Kommunikationsverbindung und die Arten der Steuerung eingegangen.

### 2.2.1 Kommunikationsverbindung

Für die Herstellung von Kommunikationsverbindungen existieren verschiedene Technologien, die entweder kabelgebunden [102, S. 3] oder drahtlos arbeiten. Aufgrund der begrenzten Reichweite werden drahtlose Verbindungen üblicherweise bevorzugt eingesetzt. Diese können sowohl privat wie beispielsweise Satellitenverbindungen als auch öffentlich wie etwa 4G-Verbindungen, sein. Während private Verbindungen den Vorteil bieten, dass die Verbindungsqualität kontrollierbar ist, kann die Qualität öffentlicher Verbindungen variieren. Insbesondere bei der Übertragung von Sensordaten ist eine Bandbreite von mehreren MBit/s erforderlich [103]. Trotzdem haben Grange et al. [104] bereits 2000 gezeigt, dass es möglich ist, Roboter über das Internet zu teleoperieren. In Bezug auf die Teleoperation von Straßenfahrzeugen hat Neumeier [105, S. 8] die theoretische Machbarkeit der Teleoperation über das öffentliche 4G-Netzwerk bestätigt, während Beiker [106, S. 18] die Kommunikationsverbindung als eines der Hauptprobleme bei der Teleoperation von Fahrzeugen auf öffentlichen Straßen identifiziert.

### Bandbreite

Vor allem die Übertragung der Sensordaten stellt hohe Anforderungen an die Kommunikationsverbindung dar. Der Rohdatenstream einer Full-HD Kamera mit  $1920 \times 1080$  Pixeln bei einer Bildwiederholfrequenz von 50 Hz beträgt  $\sim 2,5$  Gb/s, das die unter optimalen Bedingungen im LTE verfügbare Uploadbandbreite von 500 Mb/s übersteigt [107, S. 603]. Um dieser Limitierung zu umgehen, werden die Sensordaten komprimiert, wodurch eine Reduktion der Kameradaten auf  $< 10$  Mb/s möglich ist. Das Komprimierungsverfahren und der gewählte Komprimierungsgrad haben hierbei einen starken Einfluss auf die subjektiv wahrgenommene Qualität [108, S. 441]. Um als Rückfallebene für autonome Fahrzeuge dienen zu können, kann nicht von der theoretisch maximalen übertragbaren Bandbreite ausgegangen werden, sondern es muss die von verschiedenen Faktoren abhängige [109, S. 5], tatsächlich verfügbare Bandbreite angenommen werden. Abbildung 2.10 zeigt die verfügbare kombinierte Bandbreite in München während einer mehrstündigen Messfahrt, bis zu einer maximalen Bitrate von 25 Mb/s. Es ist zu erkennen, dass die kombinierte Bandbreite während der gesamten Messfahrt nicht unter 5 Mb/s sinkt.

Wie in Kapitel 2.1.6 dargestellt, verfügen HAF über eine Vielzahl verschiedener Sensoren, deren Daten potenziell übertragen werden können. Aufgrund der Anzahl an Sensoren können selbst mit Komprimierung nicht alle Sensordaten in optimaler Qualität übertragen werden. Die Bandbreitenbegrenzung erfordert gegebenenfalls die Übertragung von Sensordaten mit suboptimaler Qualität, die Auswirkungen auf die Umgebungswahrnehmung haben kann. Insbesondere die Videoqualität kann Einfluss auf die Erkennung von Objekten haben [110, S. 4, 111, S. 6] und wird in Kapitel 2.2.3 genauer besprochen.

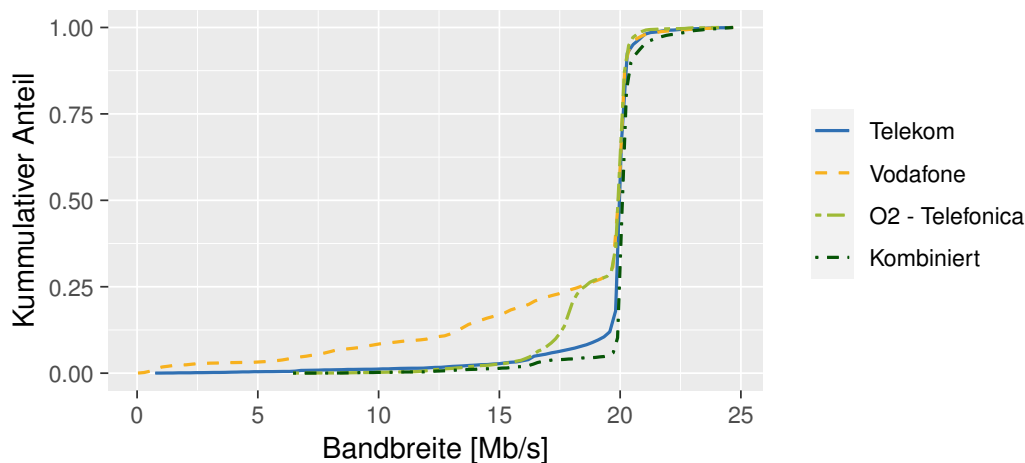


Abbildung 2.10: Kumulative Verteilungsfunktion (CDF) der erfassten Bandbreite während einer vierstündigen Messfahrt in München

## Latenz und Kommunikationsverzögerung

Aufgrund der physikalischen Limitierung der Datenübertragungsgeschwindigkeit durch die Lichtgeschwindigkeit sowie durch die verwendete Technik induzierten Verzögerungen unterliegen sowohl die Sensordaten als auch die Steuerbefehle bei der Teleoperation einer Zeitverzögerung, die auch Latenz genannt wird. Georg et al. [112] untersuchen die während der Teleoperation auftretenden Latenzen und unterscheiden hierbei zwischen Sensor- und Aktorlatenz. Sie stellen fest, dass die durch die 4G-Kommunikationsverbindung verursachte Latenz für die Steuerbefehle  $\sim 20$  ms und  $\sim 43$  ms für die Kameradaten beträgt. Der Wechsel auf den neuen Mobilfunkstandard 5G ermöglicht theoretisch eine Übertragungslatenz von weniger als 1 ms für die Funkverbindung [113, 114]. Zusätzlich zu der Kommunikationslatenz müssen verschiedene andere Verzögerungen wie z. B. Kamera-, Monitor- oder Motorlatenz bei der Teleoperation berücksichtigt werden [112]. Die Latenz hat keinen direkten Einfluss auf die Umgebungswahrnehmung, weil z. B. ein Videostream unabhängig von der Zeitverzögerung immer gleich wahrgenommen wird. Indirekt kann eine größere Komprimierungszeit bei gleicher Bitrate zu einer besseren Videoqualität führen [115]. Studien zeigen, dass durch die Latenz die Steuerung des Fahrzeugs erschwert wird [102, 116–119]. Zudem zeigt Pongrac [120, S. 201], dass eine Gesamtlatenz von mehr als 150 ms nicht nur eine verminderte Aufgabenleistung, sondern auch ein vermindertes Telepräsenzerleben zur Folge haben kann. Die durch die Gesamtlatenz auftretenden negativen Effekte können in gewissem Rahmen und von der Geschwindigkeit abhängig durch die Wahl geeigneter Assistenzfunktionen [121, 122], Anzeigehilfen [118, 123–125] und Steuerungsarten ausgeglichen werden.

### 2.2.2 Steuerungsarten / Paradigmen der Teleoperation

Im Kontext der Robotik werden drei verschiedene Steuerungsarten für Teleoperation unterschieden [126, S.781]: direkte, geteilte und überwachte Steuerung. Dem gegenüber stehen die von der SAE definierten Steuerungsarten: Remote Driving und Remote Assistance [28], die Bogdoll [32, S. 9] zudem um Remote Monitoring erweitert. Weil et al. [127, S. 9] definieren auf Basis ihrer Erfahrungen mit verschiedenen Militärfahrzeugen übergeordnet sechs Interaktionsmechanismen zwischen einem RO und einem unbemannten System: System Konfiguration, System Eingabe, Überprüfung von Systemvorschlägen, Überwachung der Missionsausführung, Verbesserung der Systemperformanz und direkte Steuerung. Abbildung 2.11 zeigt eine Übersicht über die verschiedenen Kategorisierungen.

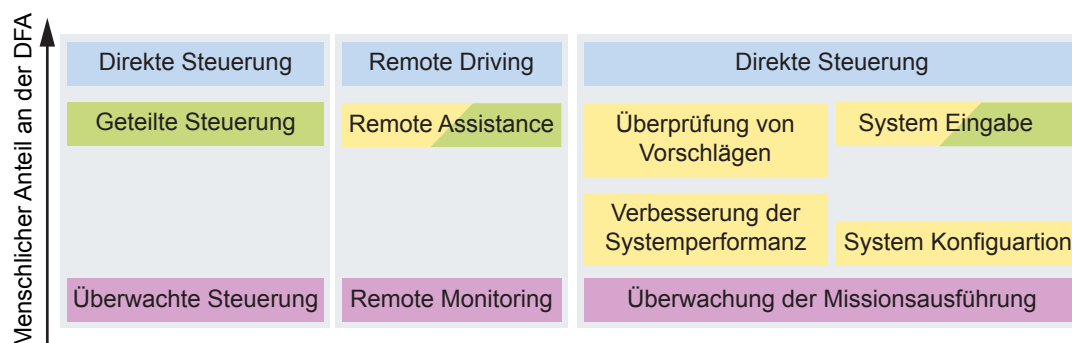


Abbildung 2.11: Übersicht über die verschiedenen Steuerungsarten und Interaktionsmechanismen. Links: Robotik [126, S. 781]. Mitte: Einordnung nach SAE [28, S. 18] und Bogdoll [32, S. 9]. Rechts: Interaktionsmechanismen in der Militärtechnik nach Weil et al. [127, S. 9].

Übergeordnet ergeben sich die folgenden Kategorisierungen:

**Direkte Steuerung:** Hierbei handelt es sich um die einfachste und am meisten verwendete Form der Teleoperation, bei der die Steuerbefehle des RO durch geeignete Eingabegeräte unmittelbar vom Roboter umgesetzt werden. Diese Steuerungsart eignet sich nur für Systeme mit geringer Gesamtlatenz, weil der Mensch die Regelaufgabe der Roboterbewegung durchführt. Bei einer höheren Latenz ist eine direkte Steuerung nur noch unter einer stark verminderten Aufgabenleistung möglich, weil der RO eine „Move and Wait“ Strategie annimmt [117].

**Indirekte / Kooperative Steuerung:** Die indirekte bzw. kooperative Steuerung ist im Vergleich mit der direkten Steuerung oder der Überwachung über die verschiedenen Anwendungsgebiete nicht klar definiert. So werden in der Robotik häufig Steuerungen verwendet, bei denen der RO und der Roboter gemeinsam die Bewegungen ausführen [128–133]. Oft wird hier die H-Metapher als Analogie verwendet [134, S. 8]. Laut der SAE kann der RO in dieser Steuerungsgruppe dem Fahrzeug z. B. Bewegungsprimitiven [135–137] vorgeben oder einfachere Befehle ausführen, wie z. B. die Modifikation der Objektklassifizierung [138, S. 52] oder die Auswahl und Freigabe von vorgeschlagenen Aktionen. Laut Weil können diese Befehle als „System Eingabe“ oder „Überprüfung von Vorschlägen“ verstanden werden.

**Überwachung:** Beim Monitoring überwacht der RO den Roboter ausschließlich und kann diesen in einem Eingriffsfall z. B. in einen risikominimalen Zustand versetzen oder mittels der direkten Steuerung die Kontrolle übernehmen. [32, 127]

Die richtige Umgebungswahrnehmung ist für alle Steuerungsarten relevant, weil sie am Anfang jedes Entscheidungsprozesses steht und ohne sie einem RO die Handlungsgrundlage fehlt [139, S. 9, 140, 141, 142, S. 41, 143]. Im Rahmen dieser Arbeit wird in Studien, die eine Fahraufgabe beinhalten, die direkte Steuerung verwendet.

### 2.2.3 Benutzerschnittstelle / HMI

Die Benutzerschnittstelle oder HMI ist der Arbeitsplatz des RO und somit eines der Hauptbestandteile jedes Teleoperationssystems, das ebenfalls bei der Entwicklung des Gesamtsystems berücksichtigt werden muss [137, 144]. Grundsätzlich können die Hauptkomponenten des HMI zwischen Eingabe- und Ausgabegeräten sowie nicht funktionalen Komponenten eingeteilt werden. Abbildung 2.12 zeigt drei in der Industrie und Forschung für die Teleoperation von HAF verwendete HMI. Diese unterscheiden sich sowohl bei den Ausgabe- als auch bei den Eingabegeräten voneinander. Ausgabegeräte dienen dazu, Informationen und Sensordaten vom



automatisierten Fahrzeug dem RO mitzuteilen. In der Regel werden Monitore oder Audiogeräte verwendet [145]. Es können jedoch auch weitere Komponenten, z. B. Head-Mounted-Display (HMD) oder Vibrationsmotoren zur Nachahmung der Straßenanregung verwendet werden [146, S. 18]. Die Eingabegeräte sind von der gewählten Steuerungsart abhängig [32] (Abbildung 2.2). So werden für die direkte Steuerung Komponenten wie Lenkräder oder Pedale verwendet, die das Fahrerempfinden in einem echten Fahrzeug nachahmen. Remote Assistance Systeme haben keine Möglichkeit das Fahrzeug direkt zu steuern, sondern nutzen den Aufgaben entsprechende Geräte wie z. B. Maus, Keyboard oder berührungsempfindliche Displays. Graf et al. [145] beschreiben den Lösungsraum und mögliche Komponenten ausführlich. In dieser Arbeit liegt der Fokus auf den Anzeigegeräten und der Darstellung der Sensordaten.

Dabei können verwirrende Schnittstellen mit kleinen, niedrig aufgelösten Videostreams, Platzbeschränkungen und Displaygröße dazu führen, dass der RO eine verminderte Umgebungswahrnehmung hat, was sich auf die Gesamtleistung auswirkt [147]. Gleichzeitig ist es unpraktisch, alle dem System zur Verfügung stehenden Informationen auf einmal anzuzeigen [148, S. 6]. Durch eine sorgfältige Gestaltung der Anzeigen und Bedienelemente des HMI können diese Probleme vermieden werden, was ein höheres Situationsbewusstsein ermöglicht [149]. So kann z. B. durch die zusätzliche Wahl geeigneter Steuerungskonzepte ein RO mit einem HMI eine Gruppe von HAF kontrollieren [150]. Im Folgenden wird auf die für die visuelle Umgebungswahrnehmung relevanten Elemente des HMI eingegangen.

## Anzeigegeräte

Aufgrund der in Kapitel 2.1.4 genannten Eigenschaften werden in Teleoperationssystemen häufig Kameras als wichtigste Informationsquelle für den RO verwendet. Kameradaten werden entweder auf Monitoren oder innerhalb von HMD dargestellt, aber auch Leinwände oder Augmented-Reality-Brillen können verwendet werden.

**Monitore:** Es gibt verschiedene Ansätze, um die Kamerabilder auf Monitoren darzustellen. Ein Ansatz ist, dass für jede Kamera ein eigener Monitor verwendet wird. So nutzt Hainsworth vier dedizierte Monitore für je eine Kamera zur Teleoperation von Minenfahrzeugen und stellt fest, dass die Bediener sich an die Sichtmuster gewöhnen [148, S. 5]. HAF verwenden eine Vielzahl an Kameras, was die Übertragung dieses Konzepts erschwert. Zudem könnte eine solche Konfiguration unübersichtlich werden. Ein anderer Ansatz, um dieses Problem zu umgehen, ist der Wechsel der Videostreams und die Ausblendung von Anzeigen, um die Anzahl der Monitore zu reduzieren. Keyes et al. [154] stellen jedoch fest, dass 80% der Probanden für die Teleoperation von einem Such- und Rettungsroboter eine feste Kamera zu Monitor Zuordnung präferieren. Eine weitere Möglichkeit ist das Stitching und die Überlagerung von verschiedenen Kameradaten, um die verwendete Monitorfläche ideal auszunutzen. Ein Beispiel hierfür ist Hofbauer et al. [155], der auf drei Monitoren sechs Kameras darstellt. Die letzte Möglichkeit ist



Abbildung 2.12: Übersicht verschiedener HMI für die Teleoperation von HAF. Links: Einride [151]. Mitte: Bout et al. [152]. Rechts: Phantom Auto [153].

eine Kombination aus den drei vorgestellten Ansätzen. Für die Darstellung der Videos im Remote Driving von HAF kommen häufig drei um den RO platzierte Monitore zum Einsatz. Diese ahmen die Frontansicht des echten Fahrers nach und werden zusätzlich mit Spiegelkameras überlagert. Kritisch anzumerken ist, dass diese Darstellungsart ein spezifisches Sensorset benötigt. In der Regel werden die Ansichten des echten Fahrers wie folgt nachgebildet: drei Kameras zur Wiedergabe der Frontansicht und drei weitere für die Spiegel. Diese Kameraansichten sind aber nicht zwangsläufig in jedem HAF vorhanden.

Für die anderen Steuerungsarten (RA und RM), die mehr Informationen des HAF zur Verfügung haben, kann die Anzahl an Monitoren reduziert werden [138, S. 74], weil z. B. auf Informationen aus einer Objekterkennung zurückgegriffen werden kann. In allen Steuerungsarten können weitere Monitore zusätzliche sekundäre Informationen wie eine Karte oder die Darstellungen des Fahrzeuginnenraums bereitstellen [153].

**HMD:** Head-Mounted-Displays werden für verschiedene Teleoperationssysteme verwendet, weil diese eine höhere Immersion und durch das damit vermutete höhere Situationsbewusstsein eine bessere Aufgabenleistung versprechen [156–159]. Neben weiteren Vorteilen ermöglichen HMD hauptsächlich die Stereopsis und die damit verbundene räumliche Wahrnehmung [160, S. 36]. Dies wird durch separate Optiken und Monitore für jedes Auge realisiert. Während im Gebiet der Teleoperation einige Veröffentlichungen zum Thema HMD existieren [161–163], sind im Kontext von HAF nur wenige Ergebnisse veröffentlicht.

Shen et al. [119] konnten ein Fahrzeug erfolgreich mit einem HMD teleoperieren. Sie verwenden eine auf einem Gimbal montierte Kamera, die eine Kameraausrichtung anhand der Kopfposition ermöglicht. Kritisch anzumerken ist die Montage der Kamera auf einem Gimbal. Diese kann aufgrund der zusätzlichen Latenz durch den Gimbal Übelkeit verursachen. Zudem ist dieses Konzept nicht auf HAF übertragbar, weil die Kameras fest verbaut sind.

Hosseini [121, 164] verwendet ein HMD zur Anzeige virtueller, zweidimensionaler Monitore und dreidimensionale Bounding-Boxen (BB) zur Visualisierung vom HAF erkannten Objekten, um die räumliche Wahrnehmung zu steigern. Kritisch anzumerken ist hier, dass keine objektive Messmethode zur Ermittlung des Situationsbewusstseins verwendet wurde, sondern Probanden ihr Situationsbewusstsein selbst einschätzen mussten. Probanden könnten ein unterschiedliches Verständnis von Situationsbewusstsein haben, was zu Abweichungen in den Ergebnissen führt. Weiterhin wurde die Studie nicht mit realen Daten validiert. Die Anzeige der Kameradaten als virtuelle Monitore innerhalb des HMD hat keine Vorteile gegenüber den realen Monitoren. Ähnliche Ergebnisse finden Kalamker et al. [165], die ein reales Remote Monitoring und Driving Interface in der virtuellen Realität exakt replizieren. Die Resultate der durchgeführten Studie zeigen, dass die Verwendung eines HMD keinen Vorteil gegenüber dem gleichwertigen realen Anzeigeformat bietet.

Bout et al. [152] vergleichen ein HMD mit einem Laptop Monitor in Kombination mit 360° Videoaufzeichnungen einer Kamera zur Ursachenfindung von Disengagements von einem stationären HAF. Die Ergebnisse zeigen, dass HMD im Vergleich mit konventionellen Laptopmonitoren eine schnellere Ursachenfindung ermöglichen. Er schließt daraus, dass das HMD ein besseres Situationsbewusstsein verursacht. Kritisch ist hier, dass die Probanden ein HMD-HMI mit einem Laptop-HMI mit Trackpad vergleichen. Dieser Vergleich scheint ungerechtfertigt, weil der Laptop Monitor deutlich kleiner ist und die Bedienung mit einem Trackpad nicht ergonomisch auf die Aufgabe ausgelegt wurde.

**Leinwände:** Eine weitere Möglichkeit ist die Projektion und Anzeige der Daten auf Leinwände. Aufgrund des Aufwands, der mit dieser Art der Darstellung verbunden ist, findet diese in der Teleoperation selten Anwendung.

## Darstellungsmöglichkeiten

**Zwei- und dreidimensionale Darstellung:** Neben der Wahl der Anzeigegeräte existieren verschiedene Möglichkeiten, wie Informationen dem RO präsentiert werden können. Konventionelle Monitore erlauben die Darstellung von zwei- als auch dreidimensionalen Inhalten. Zweidimensionale Darstellungen werden für die Teleoperation am häufigsten verwendet. Hierzu gehört z. B. die Darstellung von Kamerastreams, Karten oder anderen Sensorinformationen. 3-D-Darstellungen sind dreidimensionale visuelle Darstellungen von Informationen. Sie können dem RO ein besseres räumliches Verständnis von der dreidimensionalen Umgebung des ferngesteuerten Systems übermitteln. Beispiele für 3-D-Darstellungen sind stereoskopische Live-Video-Feeds von Kameras, die an dem ferngesteuerten System angebracht sind, oder 3-D-Modelle des ferngesteuerten Systems und seiner Umgebung. Durch die Verwendung von 3-D-Darstellungen soll der RO die räumlichen Beziehungen zwischen dem ferngesteuerten System und seiner Umgebung besser verstehen können und somit eine genauere und präzisere Fernsteuerung ausführen. Vor allem in Kombination mit HMD ergeben sich jedoch neue Möglichkeiten, weil der RO sich virtuell in die 3-D-Darstellung begeben kann und somit nicht mehr durch die Einschränkungen einer Bildschirmoberfläche limitiert ist. Dies ermöglicht nicht nur das intuitive Umschauen, sondern auch die stereoskopische Wahrnehmung von Objekten in der virtuellen Welt.

Nielsen et al. [166] vergleichen für einen Such- und Rettungsroboter eine 2-D- und eine 3-D-Darstellung auf einem Monitor, die Informationen von einer Kamera mit einer digitalen Karte überlagern. Ihre Ergebnisse zeigen, dass Probanden mit einer 3-D-Darstellung signifikant weniger Zeit zur Lösung der präsentierten Aufgaben gebraucht haben. Ähnliche Ergebnisse von Labonte et al. [167, S. 11] für die Teleoperation eines Serviceroboters unterstützen diese Aussage.

Im Kontext von HAF verwenden Bout et al. [152] eine dreidimensionale Darstellung der Fahrzeugumgebung innerhalb eines HMD, die mit einer kommerziellen Vuze+ 3D 360 VR [168] Kamera aufgenommen wurden. Die Ergebnisse zeigen, dass eine dreidimensionale Darstellung vorteilhaft sein kann. Kritisch anzumerken ist, dass das verwendete Kamerakonzept nicht auf HAF übertragbar ist.

**Stitching und Panoramadarstellungen:** Stitching ist eine Methode aus der Fotografie, die mehrere Bilder zu einem zusammenhängenden Gesamtbild verbindet. Dabei werden die Bilder verzerrt, überlagert und die Übergänge so weit angepasst, dass die einzelnen Bilder nicht mehr als solche wahrnehmbar sind. Diese Methode findet auch in der Teleoperation Anwendung. Seeman [100] entwickelt für einen Überwachungsroboter eine Methode, die im Stillstand des Roboters durch die Rotation von zwei Kameras eine 360° Panoramaansicht um den Roboter erstellt. Eine ähnliche Methode verfolgen Maxwell et al. [169] für einen Telepräsenzroboter. Krückel et al. [170] entwickeln für einen Untergrundkartierungsroboter eine Panoramadarstellung für ein HMD auf Basis von fünf Videostreams. Die Kameras sind auf einem Mast montiert und befinden sich physisch am gleichen Fluchtpunkt, wodurch die Berechnung des Panoramas vereinfacht wird. Generell kann diese Methode sichtbare Kanten zwischen Videostreams verschleiern, die von RO als störend empfunden werden können [171, S. 55]. Physische Kanten durch Monitore können durch diese Methode nicht verhindert werden. Tener et al. [172, S. 12] empfehlen auf

Basis einer Expertenstudie die Verwendung von Stitching. Derzeit existieren keine objektiven Ergebnisse zum Einfluss von Stitching auf das Situationsbewusstsein des RO.

### Kameraeigenschaften

**Extrinsische und intrinsische Kameraparameter:** Für die Teleoperation sind nicht nur das Anzeigegerät und Darstellungsart von Relevanz, sondern auch extrinsische und intrinsische Kameraeigenschaften. Diese haben einen erheblichen Einfluss auf die Teleoperation, weil sie die Qualität der visuellen Informationen beeinflussen, die dem RO über das ferngesteuerte System bereitgestellt werden. Die intrinsischen Kameraparameter betreffen die interne Geometrie der Kamera und beeinflussen die Bildqualität und -genauigkeit. Dazu gehören Parameter wie der Fokus, die Verzerrung, die Brennweite und der Sensorchip. Vor allem die Brennweite hat einen Einfluss auf die Leistung des RO. Glumm et al. [173, S. 16] zeigen, dass Probanden mit einer Kamera mit 6 mm Brennweite und 55° horizontalem Field of View (FOV), in Hinblick auf Geschwindigkeit und Genauigkeit signifikant besser gefahren sind als Probanden, die mit einem Videostream von 29° oder 94° FOV. In Hinblick auf die Vermeidung von Objekten haben die Probanden das Objektiv mit der geringeren Brennweite von 3,5 mm und 94° FOV bevorzugt, fühlten sich aber gleichzeitig unwohl mit der durch die kleinere Brennweite verursachten Vogelperspektive. Insgesamt ist nicht nur das FOV einer einzelnen Kamera relevant. Ross et al. [102, S. 7] zeigt, dass ein kleineres gesamtes FOV einen negativen Effekt auf die Aufgabenerfüllung der Probanden hat. Ähnliche Ergebnisse findet Arthur [174, S. 65] innerhalb einer Probandenstudie bei der Verwendung eines HMD.

Die extrinsischen Kameraparameter betreffen die Beziehung zwischen der Kamera und dem ferngesteuerten System. Studien zeigen, dass es für RO hilfreich ist, Teile des ferngesteuerten Roboters/Fahrzeugs in dem Videostream zu sehen [122, 154, 175] und RO sich beschweren, wenn dies nicht der Fall ist [154]. Kameras sollten zudem weiter oben platziert sein, um eine bessere Übersicht um das Fahrzeug zu ermöglichen [154].

Im Kontext von HAF wird das Sensorset inklusive dieser Parameter primär für die automatisierte Fahrfunktion ausgelegt. Das Teleoperationssystem ist hier von sekundärer Bedeutung und muss die Daten dementsprechend verarbeiten und dem RO verständlich darstellen können. In bisherigen Veröffentlichungen [119, 121, 152, 164], die sich mit der Teleoperation von HAF auseinandersetzen, werden dedizierte Kameras für die Teleoperation oder Mechaniken verwendet, die sich von den an HAF verwendeten Kameras hinsichtlich Platzierung, Auflösung und Sichtbereich unterscheiden. Teilweise werden Kameras aus dem Konsumentenbereich verwendet, die Ansichten erzeugen, die mit dem Kameraset eines HAF nicht möglich sind [152].

**Videoqualität:** Die Videoqualität wird von verschiedenen Parametern wie der Auflösung des Kamerasensors, der Qualität der Optik und den Encodereinstellungen bestimmt, wobei nur die Letzteren während der Betriebszeit des HAF und live während der Teleoperation angepasst werden können. McGovern [110, S. 4] stellt fest, dass eine hohe Qualität oder Auflösung hauptsächlich zur Wahrnehmung von Objekten notwendig ist. Für die reine Fahraufgabe reicht es, wenn ein RO die Straßenmarkierungen erkennen kann. Ross [102, S. 7] bestätigen den Einfluss der Videoqualität auf die Pfadplanung und Hoffman et al. [176] finden einen signifikanten Einfluss auf die Reaktionszeit. Cai et al. [111] untersuchen, wie viele Pixel zur Erkennung verschiedener Formen benötigt werden. So brauchen Gesichter minimal 17×17 Pixel, um von allen Probanden als solche wahrgenommen zu werden. Folglich existieren objektabhängige Grenzen, ab welchen diese nicht mehr als solche wahrgenommen werden. Weiterhin ist eine farbliche Darstellung wichtig, weil Farben zusätzliche Hinweise liefern, z. B. beim Unterschied zwischen Dreck und

Asphalt [110], auch wenn Objekte auf Schwarzweiß-Bildern im Durchschnitt weniger Pixel zur Erkennung benötigen [111]. In Zusammenhang mit HMD kann eine niedrige Qualität der gesamten visuellen Darstellung einen negativen Einfluss auf die Immersion haben [177, 178]. Generell ist die Bestrebung, dem RO die bestmögliche Qualität zur Verfügung zu stellen, sofern diese innerhalb der Grenzen der verfügbaren Datenrate liegt. Schimpe [103] stellt hierfür eine Methode mittels GNSS-gestützter Bandbreitenkarten vor, und Hofbauer et al. [179] entwickeln ein Verfahren, das die Bandbreite in Multi-Kamera-Streams um bis zu 50 % reduziert. Zur Messung der Videoqualität existieren sowohl subjektive (z. B. Mean Opinion Score (MOS)) als auch objektive (z. B. PSNR, VQM, SSIM, VMAF) Messmethoden [180, S. 8, 181]. Es gibt derzeit jedoch keine objektiven Ergebnisse, inwiefern die Videoqualität einen Einfluss auf die Aufgabenleistung oder das Situationsbewusstsein eines RO hat.

**Stereoskopie:** Eine weitere Möglichkeit, die Umgebungswahrnehmung der RO während der Teleoperation zu verbessern, ist die Stereoskopie. Studien zeigen, dass durch die Übertragung von zwei räumlich parallel versetzten Kamerastreams und die Anzeige jeweils eines Streams pro Auge das räumliche Sehen ermöglicht wird und die Leistung während der Teleoperation verbessert werden kann [22, 97, 182, 183]. Dennoch bleibt die Stereoskopie für die Teleoperation von HAF problematisch. Hauptursachen sind sowohl die Zunahme der erforderlichen Kameras am Fahrzeug als auch eine potenzielle Verdopplung der erforderlichen Bandbreite. Darüber hinaus finden Stereokamerasysteme in hochautomatisierten Fahrzeugen immer seltener Anwendung. Gründe hierfür sind die bessere Performanz von Radar bei schlechten Wetterverhältnissen [45, S.8], die vergleichbare, rechenarme Distanzmessung von LiDAR-Sensoren [184] und die Möglichkeit, Tiefeninformationen aus Monokamerasystemen zu gewinnen [185].

**Hilfselemente:** Um den RO zu unterstützen, können diesem weitere HMI-Elemente angezeigt werden. Hierbei werden dem RO z. B. zusätzliche Ansichten wie Karten [98, 186] oder Geschwindigkeitsanzeigen zur Verfügung gestellt. Eine weitere Möglichkeit ist die Überlagerung der Sensordaten mit Hilfselementen. Chucholowski [187, S. 70] überlagert die Videostreams mit verschiedenen Elementen, die dem RO die Teleoperation unter Latenz erleichtern sollen (Abbildung 2.13). Sugimoto et al. [122] überlagern die Videostreams mit den Dimensionen des ferngesteuerten Roboters und Ruikeren et al. [188] mit einer 3-D Fahrspuranzeige, die sich auf Basis von LiDAR-Daten an die dreidimensionale Geometrie der Umgebung anpasst. Auch Tener et al. [172, S. 12] finden im Rahmen einer Expertenstudie, dass die Projektion der zukünftigen Fahrspur des HAF dem RO bei der Einschätzung der Fahrzeugbewegung hilft.




Abbildung 2.13: Übersicht verschiedener Hilfselemente. Links: Prädierte Fahrzeug und Fahrradposition nach Chucholowski [187, S. 70]. Mitte: Dreidimensionale Berechnung der Fahrspur auf Basis von LiDAR-Daten und Geschwindigkeitsanzeige nach Ruikeren et al. [188]. Rechts: 3-D HMI mit überlagerten LiDAR-Daten und Karte nach Yanco et al. [95].

**LiDAR:** Wie bereits im vorherigen Abschnitt gezeigt, bieten LiDAR-Daten eine Möglichkeit, dem RO 3-D-Tiefeninformationen zur Verfügung zu stellen. Tam et al. [189] präsentieren ein Monitor- und HMD-HMI für einen sechsbeinigen Inspektionsroboter, das aufbereitete Daten von einem 1-Ebenen-LiDAR in Kombination mit einem 360° Kamerasystem anzeigt. Objektiv werden

während einer Studie keine Unterschiede zwischen dem Monitor- und HMD-HMI festgestellt. Ergebnisse über die Nützlichkeit der LiDAR-Daten werden nicht vorgestellt. Hosseini [164] stellt ein HMD HMI Konzept für einen 1-Ebenen LiDAR vor, indem er in einer Simulationsumgebung für HAF Bounding-Boxen der Fahrzeuge visualisiert. Die Ergebnisse deuten darauf hin, dass Abstände mit Entfernungsdaten besser durch RO in der Simulation eingeschätzt werden können.

### 2.2.4 Der menschliche Operator

Die Entwicklung eines geeigneten Teleoperationssystems kann nicht ohne die Betrachtung ergonomischer Aspekte erfolgen. Dabei sollte zur Steigerung der Aufgabenleistung die Anforderungen des RO in den Vordergrund gestellt werden. RO sind aufgrund ihrer örtlichen Abwesenheit vom Fahrzeug verschiedenen Herausforderungen ausgesetzt. So brauchen RO länger, um ein Situationsverständnis aufzubauen, sie müssen Latenz und Wahrnehmungshürden überwinden und es fällt ihnen schwer, sich am Ort des Fahrzeugs präsent zu fühlen. [65, S. 7]

Im Folgenden werden die für die Teleoperation relevanten psychologischen Modelle erklärt. Situationsbewusstsein, Immersion und Präsenz beschreiben den Zustand einer Person während der Nutzung eines Systems und sind damit entscheidende Faktoren für den Erfolg von Teleoperationssystemen. Die Usability ist ein subjektiver Kennwert zur Beurteilung eines Systems.

### Situationsbewusstsein

Das Konzept des Situationsbewusstseins umschreibt den mentalen Zustand einer Person, in dem sie ein präzises Verständnis ihrer Umgebung und der relevanten Ereignisse in dieser Umgebung besitzt. Darüber hinaus kann Situationsbewusstsein auch den Prozess beschreiben, durch den ein solcher Zustand erreicht wird. Situationsbewusstsein kann als Vorstufe zur Entscheidungsfindung gesehen werden [190] und ist somit für die Fahraufgabe von zentraler Bedeutung [191]. Es existieren verschiedene Definitionen [192–195] von Situationsbewusstsein, doch die am häufigsten verwendete Definition stammt von Endsleys originalem Modell: „Situation Awareness is the perception of the elements in the environment within a volume of time and space, the comprehension of their meaning and the projection of their status in the near future“ [141, S.792]. Der Aufbau des Situationsbewusstseins wird durch das Durchlaufen von drei Ebenen beschrieben (Abbildung 2.14). Zunächst erfolgt die Wahrnehmung von Elementen der Umwelt (Ebene 1), das Verständnis deren Bedeutung (Ebene 2) und die Prognose was in naher Zukunft mit diesen Elementen passieren wird (Ebene 3). Das Situationsbewusstsein-Modell von Endsley ist in zahlreichen Bereichen etabliert und hat sich als anwendbar für die Fahraufgabe erwiesen [196, S. 6, 197, 198, S. 4].

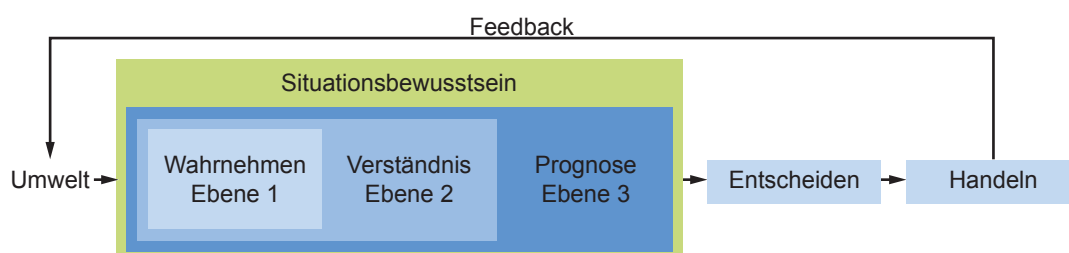


Abbildung 2.14: Dreistufenmodell des Situationsbewusstseins nach Endsley [199, S. 98]

Im Kontext der Fahraufgabe beinhalten die Anforderungen für die SituationsbewusstseinsEbene 1 die Wahrnehmung von nahen Objekten wie Fußgängern, anderen Fahrzeugen und Verkehrs-

schildern sowie die Tageszeit und Wetterbedingungen. Ebene 2 umfasst die Wahrnehmung von Objektabständen, Fahrzeugen im toten Winkel und Verkehrslinien sowie die Berücksichtigung der Auswirkungen von Wetter- und Straßenbedingungen auf die Fahrzeugsicherheit. Während des Fahrens werden die Wahrnehmung des Situationsbewusstseins und das Verständnis ständig aktualisiert, weil die Umgebung dynamisch ist und sowohl die Handlungen des Fahrers als auch anderer Verkehrsteilnehmer die fortlaufende Analyse der Situation beeinflussen. Beim Fahren wird auch die Ebene 3 benötigt, um die Wahrscheinlichkeit von Kollisionen mit anderen Objekten oder Fahrzeugen sowie die geschätzten Zeiten und Entfernungen zu Kurven oder Ausfahrten zu projizieren. [200, S. 132]

RO müssen während der Teleoperation nicht nur das Situationsbewusstsein für die entfernte Umgebung um das Fahrzeug entwickeln, sondern auch für die lokale Umgebung, für die verschiedenen Bedienelemente und Anzeigen, an denen sie arbeiten. [149].

Wickens [201, S.128-133] teilt das Situationsbewusstsein in drei weitere Bewusstseinsbereiche ein: System Awareness ist die Fähigkeit, das System, das das Fahrzeug steuert, bewusst zu verstehen und zu kontrollieren. Task Awareness beschreibt das Bewusstsein des Fahrers darüber, welche Aufgaben ausgeführt werden müssen. Der letzte Bereich, die Spatial Awareness, beschreibt die räumliche Wahrnehmung des Bedieners während der Fahrzeugsteuerung. Auch wenn diese drei Bereiche für den realen Fahrer entwickelt wurden, können sie auf den RO übertragen werden. Für diese Arbeit ist vor allem die Spatial Awareness relevant, weil RO die Einschränkungen von Monitoren ausgleichen müssen, indem sie sich mental das dreidimensionale Modell der Welt vorstellen und sich in dieses hineinversetzen [110, S. 7].

Es ist nicht eindeutig, ob das Situationsbewusstsein und die Aufgabenleistung des RO korrelieren. Einerseits zeigen Studien eine höhere Aufgabenleistung mit steigendem Situationsbewusstsein [202], andererseits garantiert ein hohes Situationsbewusstsein nicht automatisch das Treffen einer richtigen Entscheidung. So kann ein Operator ein gutes Situationsbewusstsein haben, aber daraufhin dennoch eine schlechte oder falsche Entscheidung treffen [190].

## Immersion

Immersion ist ein psychologischer Zustand, der dadurch gekennzeichnet ist, dass sich eine Person von einer Umgebung, die einen kontinuierlichen Strom von Informationen bietet, umhüllt fühlt und mit ihr interagiert [203, S. 7]. Sie ist ein Maß dafür, wie sehr die virtuelle Umgebung die Aufmerksamkeit der Person fesseln und ihr das Gefühl geben kann, in ihr präsent zu sein, indem sie eine Illusion der Realität vermittelt [204, S. 3]. So kann eine hochgradig immersive Erfahrung der Person das Gefühl geben, dass sie sich tatsächlich in der virtuellen Umgebung befindet, so als wäre es ein realer physischer Raum. Die Immersion kann durch eine Vielzahl von Faktoren beeinflusst werden, darunter die Qualität der Grafik und des Tons, der Grad der Interaktivität und das Ausmaß des physischen Feedbacks. Generell hängt die Immersion von den Einstellungen der Person [203, S. 7] aber auch von technologischen Aspekten, wie z. B. der Größe des Monitors [205, S. 17] oder der Auflösung des HMD [177, 178] ab. Obwohl keine Korrelation zwischen Immersion und Aufgabenleistung von RO bekannt ist, wird generell das Ziel einer vollständigen Immersion verfolgt [178].

## Telepräsenz

Immersion und Telepräsenz sind zwei verwandte, aber unterschiedliche Konzepte im Bereich der Teleoperation. Während die Immersion beschreibt, inwiefern sich eine Person von einer

virtuellen Darstellung umgeben fühlt, beschreibt die Telepräsenz, inwiefern sich eine Person fühlt, an einem entfernten Ort zu sein, ohne dort physisch anwesend zu sein [206, S. 227, 207, S. 22, 208]. Almeida et al. [156] vermuten, dass eine höhere Telepräsenz dazu beitragen kann, dass RO schneller Situationsbewusstsein aufbauen. Umgekehrt wird angenommen, dass das Situationsbewusstsein das Ausmaß an Telepräsenz anzeigen kann [209]. Ein Mangel an Telepräsenz könnte Auswirkungen auf die Leistung des RO haben [164]. Verschiedene Faktoren wie Bildschirmgröße [210, S. 306], Auflösung [102, 182], Intuitivität der Schnittstelle [211, S. 60], Anzeigegerät [212], FOV [174, S. 71] und Schwierigkeitsgrad der Aufgabe [209] haben Einfluss auf den Grad der Telepräsenz. Telepräsenz wird als Voraussetzung für die Teleoperation gesehen [105, 213].

### **Mentale Beanspruchung und Performanz**

Der Begriff Workload bezieht sich auf den Teil der mentalen Ressourcen, der benötigt wird, um eine Aufgabe erfolgreich zu absolvieren [214, S. 23]. Dabei kann ein zu hoher oder zu niedriger Workload in Abhängigkeit von der Aufgabenschwierigkeit zu einer verringerten Performanz führen [214, S. 24].

Aufgrund der sicherheitsrelevanten Aufgabe während der Teleoperation ist es umso wichtiger, eine Überbeanspruchung der RO zu verhindern. So konnten Thomson et al. [215, S. 85] feststellen, dass ein erhöhter Workload zu einer reduzierten Performanz führte. Mögliche Gründe für den erhöhten Workload bei der Teleoperation sind z. B. die mentale Belastung durch den mentalen Aufbau eines 3-D Modells der Umgebung [167, S. 4] oder die Verwendung von mehreren Kamera-Streams [65, S. 13]. Aber auch die verwendete Steuerungsart des Fahrzeugs hat einen Einfluss auf den Workload. So konnte Feiler [138, S. 86] einen signifikanten Unterschied im Workload zwischen der Lösung eines Disengagements mithilfe der RD oder RA feststellen.

Endsley [216, S. 31] zufolge ist eine erhöhte mentale Belastung eine von acht Einflussfaktoren, die sich nachteilig auf das Situationsbewusstsein auswirken. Weitere Faktoren sind z. B. 'Information-Overload' oder 'Out of the loop syndrom', das in Zusammenhang mit automatisierten Systemen auftreten kann. Der Workload ist somit eine der subjektiven Messgrößen, die bei der Gestaltung eines HMI berücksichtigt werden muss.

### **Usability / Gebrauchstauglichkeit**

Der Begriff Usability wird oft als Gebrauchstauglichkeit ins Deutsche übersetzt und bezieht sich auf die Fähigkeit eines Produkts, die Anforderungen des Benutzers effizient, effektiv und zufriedenstellend zu erfüllen. Ein Vorgehen zur Erlangung der Gebrauchstauglichkeit ist in der DIN EN ISO 9241-11 [217] festgelegt.

Um die Usability eines Produkts sicherzustellen, müssen die Anforderungen an das Produkt in Bezug auf Effizienz, Effektivität und Zufriedenheit des Benutzers erfüllt werden. Effektivität bezieht sich dabei auf das Erreichen von Genauigkeit und Vollständigkeit der Ziele, während Effizienz anhand des Aufwands bewertet wird, der benötigt wurde, um die geforderten Ziele zu erreichen. Diese beiden Kennwerte sind objektiv messbar.

Die subjektive Zufriedenheit des Benutzers hängt mit dem Komfort und der Akzeptanz des Produkts zusammen und kann auch Aspekte wie Identifikation mit dem Produkt oder Ästhetik beinhalten. Für die Evaluierung der Meinung des Benutzers werden Fragebögen empfohlen. Die



DIN EN ISO 9241-210 [218] enthält Vorschriften zur benutzerzentrierten Evaluierung und hebt deren Wichtigkeit für die Gestaltung von Produkten hervor. Besonders hilfreich kann eine solche Evaluierung sein, um eine Rückmeldung über die Stärken und Schwächen eines Systems zu erhalten.



# 3 Ableitung der Forschungsfragen aus dem Stand der Wissenschaft

In diesem Textabschnitt werden die wesentlichen Erkenntnisse aus dem aktuellen Stand der Wissenschaft zusammengefasst und offene Forschungsfragen identifiziert. Anschließend wird die Themenauswahl präzisiert und die zentralen Fragestellungen abgeleitet.

## 3.1 Zusammenfassung des Forschungsstands

Teleoperation ist eine Technologie, die in vielen Bereichen eingesetzt werden kann. Im Straßenverkehr kann sie beispielsweise dazu dienen, ein HAF in Grenzsituationen zu unterstützen. Auch in Zukunft ist auf Basis der Disengagement Reports davon auszugehen, dass Grenzsituationen vorkommen werden. Der RO, der die Lösung dieser Situation als Aufgabe hat, muss im Zweifel sicherheitskritische Entscheidungen treffen. Hierzu muss er zunächst ein Umgebungs- und Systemverständnis aufbauen, das als Grundlage der Entscheidungsfindung dient und anschließend mit einem geeigneten Interaktionskonzept die Situation lösen.

Die Interaktionskonzepte lassen sich in die direkte Steuerung, die indirekte beziehungsweise kooperative Steuerung und die Überwachung einteilen. Im Kontext von HAF haben sich die Begriffe Remote Driving, Remote Assistance und Remote Monitoring etabliert [28]. Remote Driving ist als letzte Rückfallebene von teleoperierten HAF zu betrachten [32]. Die Latenz hat auf die Aufgabenleistung während Remote Driving den größten Einfluss und wurde bereits in mehreren Veröffentlichungen untersucht [32, 102, 116, 118, 219]. Ein Zusammenhang zwischen Latenz und Aufgabenleistung während Remote Driving von HAF ist vorhanden, konnte jedoch noch nicht genauer definiert werden. Es lassen sich möglicherweise Rückschlüsse auf den Zusammenhang zwischen Latenz und Aufgabenleistung aus anderen Gebieten der Teleoperation ziehen. Weiterhin wurden verschiedene Hilfselemente entwickelt, um dem RO bei der Fahraufgabe unter Latenz zu unterstützen. Im Hinblick auf die indirekte/kooperative Steuerung von HAF existieren Veröffentlichungen, die mit verschiedenen Modulen aus der Sense-Plan-Act-Architektur autonomer Systeme zusammenarbeiten. Diese reichen von einer Trajektorienvorgabe und kooperativen Steuerung [128, 136, 220] bis zur Modifikation der Objektklassifizierung [138] und Freigabe von Manövern. Für den Aufbau des Situationsbewusstseins werden dem RO Sensor- und Fahrzeugdaten wiedergegeben. Kameradaten sind die häufigste Datenquelle und werden in der Regel auf Monitoren oder innerhalb von HMD visualisiert. Ein geeignetes Anzeigekonzept hängt dabei stark von den am Roboter vorhandenen Sensoren ab. Neben der Anzahl an Sensoren haben auch die extrinsischen und intrinsischen Parameter einen Einfluss auf das HMI und das Situationsbewusstsein. HAF unterscheiden sich durch die Vielzahl an Sensoren und deren Platzierung maßgeblich von anderen teleoperierten Robotern. Die Erkenntnisse aus anderen HMI können somit nur bedingt übertragen werden. Die existierenden

### 3 Ableitung der Forschungsfragen aus dem Stand der Wissenschaft

Tabelle 3.1: Vergleichende Darstellung von Veröffentlichungen im Bereich der Teleoperation und Einordnung dieser Arbeit. (✓: Vorhanden, „-“: Nicht vorhanden, Mo.: Monitore, L.:Laptop, sim.: Simulation, LZ.:Langzeit ,S+R: Such und Rettung, Dediziert: Eine Kamera pro Monitor, SB.: Situationsbewusstsein)

Quelle	Anwendung	Monitore	HMD	Kameras	LiDAR	HMI-Typ	Daten	Fokus	Studie
Hofbauer [155]	HAF RD	3	-	6	-	2D	sim.	System	✓
Tener [172]	HAF RD	1	-	4	-	2D	real	System	-
Georg [221]	HAF RD	3	✓	3	✓	2D,3D	real	Latenz	✓
Shen [119]	HAF	L.	✓	2	-	2D,Stereo	real	System	-
Kettwich [66]	HAF	7	-	3	-	2D	real	HMI	✓
Mutzenich [222]	HAF	1	-	1	-	2D	real	SB.	✓
Feiler [138]	HAF RA	1	-	1	-	2D	sim.	Steuerung	✓
Bout [152]	HAF RA	L.	✓	1x360°	-	3D Spherical	real	HMI	✓
Hosseini [164]	Carsharing	-	✓	4	-	3D+BB	sim.	HMI	✓
Tang [223]	Carsharing	3	-	4	-	2D	real	Sicherheit	✓
Gnatzig [136]	Carsharing	3	-	4	-	2D	real	Steuerung	✓
Chucholowski [123]	Carsharing	3	-	4	-	2D	real	Hilfselement	✓
Ross [102]	Militär RD	5	-	5	-	Dediziert	real	System	✓
Ruikeren [188]	Militär RD	1	-	1	✓	2D	real	Hilfselement	-
Kelly [224]	Militär RD	1	-	Stereo	✓	3D	real	HMI	✓
Appelqvist [89]	Militär RD	L.	-	1	-	2D	real	System	-
Bodell [225]	LKW	1	-	3	-	2D,stitched	sim.	System	✓
Kot [163]	S+R	-	✓	2	-	3D,Stereo	real	HMI	-
Keyes [154]	S+R	1	-	2	-	Dediziert	real	Kamera	✓
Bruemmer [226]	S+R	1	-	1	-	2D,3D+Karte	real	Karte	✓
Chen [227]	S+R	1	-	2	-	2D,Stereo	sim.	Stereo.	✓
Nielsen [166]	S+R	1	-	1	-	3D	sim.	2D/3D	✓
Martins [97]	S+R	1	✓	1	-	2D	real	HMD	✓
Parasuraman [228]	S+R	1	-	1	-	2D	real	HMI	✓
Lager [162]	Marine	-	✓	1	-	3D	sim.	HMI	✓
Seeman [100]	Inspektion	1	-	2	-	3D,Panorama	real	HMI	-
Tam [189]	Inspektion	1	✓	1x360°	✓	3D+BB	real	HMI	✓
Lee [182]	Service	1	-	2	-	Stereo	real	FF.,HMI.	✓
Mast [98]	Service	1	-	1xRGB-D	-	3D+Karte	real	Karte	✓
Jankowski [158]	Service	-	✓	2	-	Stereo	real	HMI	✓
Labonte [167]	Service	1	-	1	✓	3D	real	HMI	✓
Krücke [170]	Service	-	✓	5	-	3D,Sphere	real	HMI	-
Chellali [229]	Service	1	✓	1	-	3D,Map	sim	HMI	-
Peppoloni [230]	Manipulator	-	✓	1	-	3D	real	HMI	-
➤	HAF RD	3	✓	8	✓	3D,2D,Pano Stitch.,Spheri.	real	HMI,SB.	✓ LZ.

Veröffentlichungen im Bereich von HMI für HAF geben keinen repräsentativen Zusammenhang zwischen Darstellungsform, Anzeigegeräten und Situationsbewusstsein wieder. Weiterhin wird eine verminderte Tiefenwahrnehmung häufig als Einschränkung während der Teleoperation beschrieben [61, 65, 97, 172, 183, 227, 231–239]. Der Einsatz von Stereokamerasystemen zur verbesserten Tiefenwahrnehmung ist für HAF nicht möglich. Eine Alternative bieten die in HAF vorhandenen LiDAR-Sensoren, die Tiefeninformationen erfassen. Es existieren nur wenige Veröffentlichungen, die eine Nutzung von LiDAR-Daten für teleoperierte Systeme untersuchen. Im Bereich von HAF existiert eine Veröffentlichung, die LiDAR-Daten zur Visualisierung von Bounding Boxes verwendet, jedoch betrachtet diese Veröffentlichung nur simulierte Daten.

Ein weiterer möglicher Einfluss auf das Situationsbewusstsein ist die Videoqualität. So beschwerten sich RO über eine schlechte Videoqualität und Objekte sind ab einer bestimmten Pixelauflösung nicht zu erkennen. In innerstädtischen Bereichen kann jedoch von einer Mindestbandbreite und somit Mindestqualität ausgegangen werden. Derzeit gibt es keine Veröf-

fentlichungen, die den Zusammenhang zwischen Videoqualität und Situationsbewusstsein für Teleoperation untersuchen.

Zuletzt wird das Situationsbewusstsein häufig im Zusammenhang mit teleoperierten Systemen referenziert. Ein oft verwendetes Studiendesign beinhaltet die Schulung der Operatoren und die Durchführung des Versuchs innerhalb eines Tages. Die Lernkurve beim Umgang mit komplexen Systemen erfordert eine längere Interaktion mit dem System. Es existieren keine Studien, die den Langzeiteffekt auf Modelle wie Situationsbewusstsein, Immersion und Telepräsenz im Kontext von teleoperierten Systemen untersuchen.

Tabelle 3.1 zeigt eine Übersicht über die relevanten Veröffentlichungen und die Einordnung dieser Arbeit in der letzten Zeile.

## 3.2 Eingrenzung des Themas und Formulierung der Forschungsfragen

Wie bereits in den vorherigen Kapiteln dargestellt wurde, stellt Remote Driving unter den drei teleoperierten Steuerungsarten für HAF die letzte Rückfallebene dar, mit der ein RO ein Fahrzeug aus einer Grenzsituation befreien kann. Im Gegensatz zu anderen Steuerungsmodi kann der RO beim Remote Driving möglicherweise nicht auf Automatisierungsfunktionen wie Objekterkennung oder Lokalisierung zurückgreifen, sondern ist auf die Sensordaten angewiesen, um ein angemessenes Situationsbewusstsein zu entwickeln. Während die Steuerungsarten Remote Assistance und Remote Monitoring aufgrund ihrer Integration in das hochautomatisierte Fahrzeug spezifische HMI-Lösungen erfordern, orientieren sich Remote Driving Lösungen stärker an der realen Fahrerfahrung und sind somit breiter anwendbar. Der Fokus dieser Arbeit liegt daher auf dem Remote Driving.

Während RD ist der Aufbau von Situationsbewusstsein von verschiedenen Faktoren abhängig, wie z. B. Kameraparametern, Anzeigegerät oder Darstellungsform der Sensordaten. Kamera- und andere Sensorparameter werden überwiegend vom HAF festgelegt und dienen als Rahmenbedingungen, die das teleoperierte Teilsystem handhaben können muss.

Unter Berücksichtigung des aktuellen Forschungsstands und der Themeneingrenzung kann die im Folgenden übergeordnete Forschungsfrage formuliert werden:

- **Forschungsfrage 1: Gestaltung und Evaluation des HMI für die Teleoperation von HAF**

Wie sieht ein geeignetes Anzeigekonzept für die direkte Steuerung von automatisierten Fahrzeugen aus?

Auf Basis der übergeordneten Forschungsfrage ergeben sich drei weitere Teilfragen. Die erste Teilfrage bezieht sich auf die Entwicklung geeigneter Anzeigegeräte und Darstellungsformen.

- **Teilfrage A: Entwicklung geeigneter Darstellungsformen für HMD und Monitore**

Welche visuellen Darstellungsformen und Anzeigegeräte sind geeignet, um ein ausreichendes Level an Situationsbewusstsein zu erreichen?

Zudem wird untersucht, inwiefern Kamera- und LiDAR-Daten genutzt werden können, um die Tiefenwahrnehmung von Operatoren zu verbessern.

- **Teilfrage B: Sensordatenfusion von Kamera- und LiDAR-Daten**

Wie können die Informationen aus Kamera- und LiDAR-Sensoren kombiniert werden, um die Tiefenwahrnehmung des RO zu verbessern?

In der letzten Teilfragestellung wird der Zusammenhang zwischen der Qualität der Kameradaten und dem Situationsbewusstsein des RO im Rahmen der innerstädtischen Bandbreitengrenzen untersucht.

- **Teilfrage C: Einfluss der Videoqualität**

Wie beeinflusst die Qualität der Kameradaten das Situationsbewusstsein der Benutzer des Systems?

Weiterhin werden Langzeiteffekte untersucht, die mit zunehmender Systemerfahrung entstehen. Der Fokus liegt hierbei auf der Erfassung der Entwicklung des Situationsbewusstseins, der Immersion, der Telepräsenz und der Gebrauchstauglichkeit.

- **Forschungsfrage 2: Veränderung der Mensch-Maschine-Interaktion mit zunehmender Systemerfahrung**

Wie wirkt sich eine zunehmende Systemerfahrung auf die Mensch-Maschine-Interaktion bezüglich der Entwicklung des Situationsbewusstseins, der Immersion, der Telepräsenz und der Gebrauchstauglichkeit aus?

Das nächste Kapitel zeigt das Vorgehen und die gewählte Methodik zur Beantwortung der aufgestellten Forschungsfragen 1 und 2 auf.

# 4 Methodik

In den nachfolgenden Abschnitten werden das ausgewählte Vorgehen sowie die angewandte Methodik vorgestellt, die zur Untersuchung der aufgestellten Forschungsfragen herangezogen wurden.

## 4.1 Übergeordnete Makromethode

Um die in Kapitel 3 aufgestellten Forschungsfragen zu beantworten, wird die gewählte Methodik an den Phasen der DIN EN ISO 9241-210 [218] ausgerichtet. Diese beschreibt den Prozess zur Gestaltung gebrauchstauglicher interaktiver Systeme und umfasst einen iterativen Entwicklungsprozess, der aus vier Phasen besteht (Abbildung 4.1). Im ersten Schritt erfolgt die Analyse

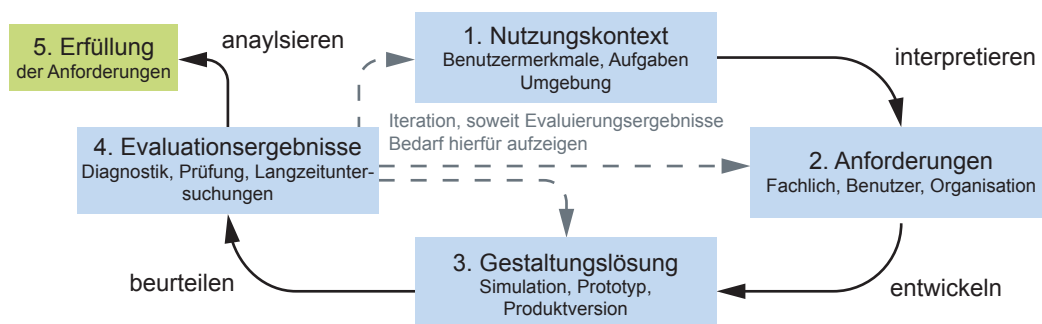


Abbildung 4.1: Gestaltungsprozess nach DIN EN ISO 9241-210 [218, S. 9]

des Nutzungskontextes, um den zugrundeliegenden Kontext zu verstehen und zu beschreiben. Im zweiten Schritt werden die Nutzungsanforderungen spezifiziert, und erste geeignete Gestaltungslösungen entworfen. Der dritte Schritt umfasst die Evaluation der Gestaltungslösungen aus der Benutzerperspektive unter Einbezug der zuvor aufgestellten Anforderungen [218, S. 9].

Die DIN EN ISO 9241-210 beschreibt einen iterativen Prozess, bei dem die vier Phasen so lange durchlaufen werden, bis die finale Gestaltungslösung den Nutzungsanforderungen entspricht. Sie bietet dabei eine Struktur für den menschenzentrierten Gestaltungsprozess. Die Norm legt jedoch keine spezifischen Methoden für die Bearbeitung der einzelnen Phasen fest [218, S. 9].

## 4.2 Anwendung der Methodik zur Beantwortung der Forschungsfragen

Die im vorherigen Kapitel beschriebene Methodik wird angewendet, um ein Vorgehen zur Beantwortung der Forschungsfragen zu erarbeiten. Das Vorgehen ist in Abbildung 4.2 abgebildet

und besteht aus sechs Unterpunkten. Die Einordnung jedes einzelnen Unterpunkts in die übergeordnete Methodik ist links und zu den einzelnen Forschungsfragen rechts dargestellt.

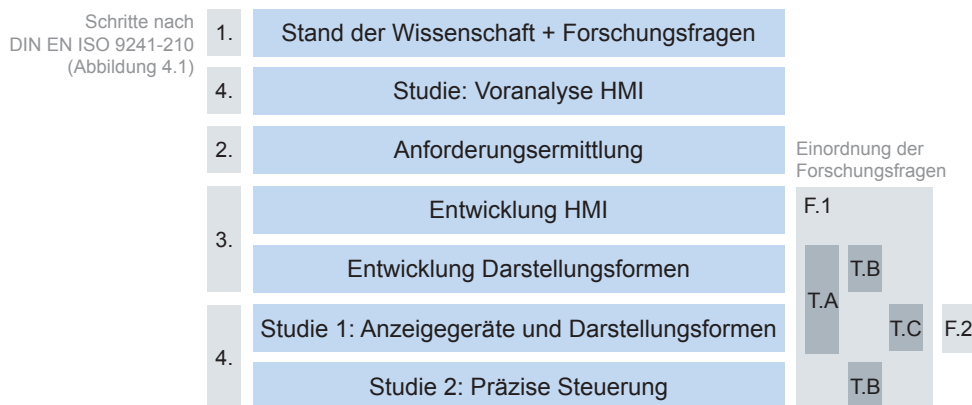


Abbildung 4.2: Darstellung des Vorgehens dieser Arbeit anhand des Gestaltungsprozesses nach DIN EN ISO 9241-210 und Zuordnung der Forschungsfragen

## Evaluierung HMI

In Anbetracht des Forschungsstandes, der in diesem Bereich am Lehrstuhl für Fahrzeugtechnik existiert [123, 130, 136, 137, 164, 187, 240–242], nutzt diese Arbeit die bisherigen Ergebnisse als Ausgangspunkt. Einzig der Nutzungskontext wird im Rahmen des Stands der Wissenschaft und der Forschungsfragen genauer definiert. Hosseini [121] hat eine Studie zur Evaluierung des HMI in der Simulation durchgeführt und dabei verschiedene Ansätze zur Verbesserung der Fahrzeugsteuerung und Umgebungsdarstellung untersucht. Ziel dieses Abschnitts ist es, das von Hosseini entwickelte HMI mit einem realen Fahrzeug zu evaluieren und die Übertragbarkeit der Ergebnisse auf das reale Fahrzeug zu untersuchen.

Hierfür werden verschiedene Änderungen an dem von Hosseini entwickelten HMI vorgenommen. Diese umfassen beispielsweise die Integration der realen LiDAR-Daten des Fahrzeugs sowie die Panoramadarstellung von Kameradaten zur Verbesserung der visuellen Übereinstimmung zwischen den Kamera- und LiDAR-Daten. Weiterhin werden auch andere Aspekte des HMI, wie die Anordnung von Anzeigergeräten und die Wahl der Darstellungsform (2-D/3-D), berücksichtigt und mögliche Auswirkungen auf die Umgebungswahrnehmung des Remote Operators untersucht.

Ziel der Evaluierung ist es einerseits, eine objektive Einschätzung über die Steuerbarkeit des Fahrzeugs in engen Situationen zu gewinnen, weil hier das Einschätzen von Entfernungen besonders wichtig ist, aber auch subjektive Einschätzungen der Probanden zu erhalten. Die Probanden werden dabei gebeten, das Fahrzeug in verschiedenen Szenarien zu steuern, die speziell für die Evaluierung der Steuerbarkeit in engen Situationen ausgelegt sind. Hierbei werden sowohl objektive als auch subjektive Daten gesammelt, wie beispielsweise die Zeit zur Bewältigung der Szenarien, die Anzahl der Kollisionen sowie die Einschätzungen der Probanden zur Verständlichkeit und Benutzerfreundlichkeit des HMI.

## Anforderungsermittlung

Der Punkt „Anforderungsermittlung“ ist ein wesentlicher Schritt im menschenzentrierten Gestaltungsprozess nach der DIN EN ISO 9241-210 [218, S. 9]. Dabei geht es darum, die Anfor-



derungen an das zu gestaltende System aus der Perspektive der Nutzer und ihrer Aufgaben zu ermitteln und zu spezifizieren. In diesem Schritt werden die Bedürfnisse, Erwartungen und Anforderungen der Nutzer analysiert und dokumentiert. Die Anforderungsermittlung kann auf verschiedene Arten erfolgen, wie zum Beispiel durch die Durchführung von Interviews, Beobachtungen oder Workshops mit den Nutzern sowie durch eine Literaturrecherche.

In diesem Abschnitt werden die Anforderungen an das HMI hinsichtlich der Sensordatendarstellung zusammengefasst. Hierbei dienen sowohl die Ergebnisse der vorangegangenen Voranalyse als auch die Literatur als Grundlage für die Identifikation der Anforderungen.

## **Entwicklung HMI**

Im Punkt „Entwicklung HMI“ wird auf Basis der Anforderungen die Grundstruktur des HMI implementiert. In diese können die verschiedenen Darstellungsformen, wie z. B. 2-D- oder 3-D-Darstellungen von Kamera- und LiDAR-Daten, integriert werden. Insgesamt zielt die Entwicklung der Grundstruktur des HMI darauf ab, eine Basis zu schaffen, mit deren Hilfe die Forschungsfragen beantwortet werden können. Hierbei wird darauf geachtet, dass die Grundstruktur des HMI den Anforderungen der Nutzer entspricht.

## **Entwicklung Darstellungsformen**

Im Abschnitt „Entwicklung Darstellungsformen“ werden Gestaltungslösungen für das HMI zur Fusionierung von Kamera- und LiDAR-Daten entwickelt. Hierbei werden die Anforderungen der Nutzer, die in der Anforderungsermittlung ermittelt wurden, berücksichtigt. Es handelt sich hierbei um einen iterativen Prozess, der aus verschiedenen Phasen besteht. In der ersten Phase werden verschiedene Konzepte und Gestaltungslösungen entwickelt und skizziert. In der zweiten Phase werden diese prototypisch umgesetzt und eine Endauswahl aus den Konzepten getroffen. Der Entwicklungsprozess endet mit der Implementierung der finalen Gestaltungslösung in das System.

## **Studie Anzeigeräte und Darstellungsformen**

Dieser Abschnitt widmet sich der Untersuchung der Auswirkungen unterschiedlicher Anzeigeräte und Darstellungsformen auf den RO. Hierfür werden die zuvor entwickelten HMI-Prototypen in einer Studie getestet und hinsichtlich des Situationsbewusstseins, der Immersion, der Telepräsenz und der Videoqualität verglichen. Jeder Proband wird hierbei einem spezifischen Anzeigekonzept zugewiesen, das im Rahmen eines In-Between-Group-Designs während der gesamten Studie beibehalten wird. Die Studie umfasst vier Termine, die über einen Zeitraum von vier Wochen verteilt sind. Während der Termine werden den 29 Probanden insgesamt 28 Videoaufnahmen in unterschiedlicher Qualität von realen Fahrszenen präsentiert. Durch verschiedene Fragebögen werden das Situationsbewusstsein, die Immersion, die Telepräsenz und die Gebrauchstauglichkeit erfasst. Zur Evaluierung der Übertragbarkeit umfasst der letzte Termin eine reale Fahrt mit dem Versuchsfahrzeug. Die Studie zielt darauf ab, die Auswirkungen unterschiedlicher Anzeigeräte und Darstellungsformen auf den RO zu untersuchen und Empfehlungen für eine optimale Kombination abzuleiten.

### **Studie LiDAR-Darstellung**

Aus den entwickelten HMI-Prototypen wird eine Vorauswahl getroffen, die für die Studie zur LiDAR-Datendarstellung verwendet wird. Die ausgewählten HMI-Prototypen werden in einer Studie evaluiert, um die Auswirkungen von LiDAR-Daten auf die Tiefen- und Umgebungswahrnehmung zu untersuchen. Um eine Vergleichbarkeit zwischen den HMI-Varianten zu gewährleisten, wird das gleiche Studiendesign wie in der Voranalyse gewählt. Die Ergebnisse der Studie werden präsentiert und mit denen aus der Voranalyse verglichen.

# 5 Vorgehen

In diesem Kapitel wird das Vorgehen zur Entwicklung eines HMI zur Fusionierung von Kamera und LiDAR sowie zur Untersuchung der Auswirkungen von Anzeigegeräten und Darstellungsformen auf das Situationsbewusstsein des RO detailliert beschrieben.

## 5.1 Voranalyse

Die Studie zur Voranalyse wird in [221] im Detail vorgestellt und in dieser Arbeit in den wesentlichen Zügen zusammengefasst.

### 5.1.1 Ziele

Das Ziel der Voranalyse besteht darin, das bestehende System und dessen Eigenschaften besser zu verstehen und einen Referenzpunkt für die weitere Arbeit sowie Anforderungen für die nächste HMI-Iteration von realen Nutzern zu erhalten. Zudem soll das von Hosseini [164] entwickelte HMD-HMI mit einem realen Fahrzeug evaluiert werden. Es soll eine objektive Einschätzung über die Steuerbarkeit des Fahrzeugs in engen Situationen gewonnen werden, weil hier das Einschätzen von Entfernungen besonders wichtig ist. Zu diesem Zweck wird eine Realfahrzeugstudie geplant und durchgeführt. Folgende Hypothesen sollen getestet werden:

- H<sub>1</sub>: Das HMD hat keinen Einfluss auf die präzise Steuerung des Fahrzeugs.
- H<sub>2</sub>: Es existiert kein Unterschied im Realitätsempfinden innerhalb der VR-Umgebung.
- H<sub>3</sub>: Die Verwendung eines HMD erhöht den Workload.

Die Probanden werden gebeten, das Fahrzeug in verschiedenen Szenarien zu steuern, die speziell für die Evaluierung der Steuerbarkeit in engen Situationen ausgelegt sind. Hierbei werden sowohl objektive als auch subjektive Daten gesammelt, wie beispielsweise die Zeit zur Bewältigung der Szenarien, die Anzahl der Kollisionen sowie die Einschätzungen der Probanden zur Verständlichkeit und Benutzerfreundlichkeit des HMI.

### 5.1.2 Probanden

Vor Beginn des Versuchs werden die Teilnehmer gebeten, einen demografischen Fragebogen auszufüllen. Es nehmen insgesamt acht Personen teil (vier Frauen und vier Männer) mit einem Durchschnittsalter von 24,25 Jahren. Alle Teilnehmer sind Studenten mit einer durchschnittlichen Fahrerfahrung von sieben Jahren und einer jährlichen Fahrstrecke von etwa 5000 km. Drei Teilnehmer haben einen sportlichen Fahrstil, während die anderen Teilnehmer eher einen passiven oder lässigen Fahrstil bevorzugen. Nur ein Teilnehmer spielt regelmäßig Videospiele, drei Teilnehmer spielen einmal pro Woche und vier spielen nie Videospiele.

### 5.1.3 Versuchsaufbau und Durchführung

#### Versuchsfahrzeug

Das Versuchsfahrzeug ist ein Drive-by-Wire Audi Q7 mit vier Kameras, die jeweils  $90^\circ$  HFOV und  $52^\circ$  VFOV haben. Weiterhin befinden sich zwei 1-Ebenen-LiDAR mit  $180^\circ$  HFOV vorne und hinten am Fahrzeug auf der Höhe der Stoßstange. In Abbildung 5.1 sind die sichtbaren Bereiche der Sensoren farblich markiert. Alle Kameras sind im Innenraum des Fahrzeugs angebracht. Dies führt insbesondere bei den Seitenkameras zu Abschattungen durch die A-Säule und bei der Frontkamera zur Abschattung durch die Motorhaube. Der Nahbereich vor und hinter dem Fahrzeug wird allein durch die LiDAR-Sensoren abgedeckt. Die Abdeckung des seitlichen Nahbereichs ist nicht möglich. Das Versuchsfahrzeug wird über die Dauer der Studie nicht variiert.




Abbildung 5.1: Sensorlayout Audi Q7. Links: Vogelperspektive. Rechts: Seitenansicht.

#### HMI

Für das HMI werden die Bedingungen Monitor und HMD variiert. Abbildung 5.2 zeigt eine Bildschirmaufnahme von dem verwendeten Monitor-HMI für die Studie. In der unteren rechten Ecke ist eine Visualisierung der LiDAR-Daten aus der Vogelperspektive zu sehen, die auch die Fahrzeugdimensionen beinhaltet. Auf dem linken und rechten Kamerabild nimmt ein Großteil der A-Säule ein. In der Mitte befindet sich eine Geschwindigkeits- sowie Ganganzeige. Ab-



Abbildung 5.2: Bildschirmaufnahme des Monitor-HMI inklusive LiDAR-Daten Visualisierung [171, S. 23]

Abbildung 5.3 zeigt das HMD-HMI. Als HMD wurde das Oculus Rift Development Kit 2 (DK2) verwendet (Abbildung 5.4). Es wurden minimale Anpassungen am originalen HMI vorgenommen. Anstelle virtueller, flacher Monitore kamen zylinderförmige Flächen zum Einsatz, um die realen FOV der Kameras darzustellen. Objekte, die sich beispielsweise links vom Fahrzeug befinden, werden auch innerhalb des HMD auf den Kamerabildern links vom Fahrzeug angezeigt. Zusätzlich verbessert sich die Überlagerungsgenauigkeit der durch die blauen Blöcke dargestellten LiDAR-Daten relativ zu den Kamerabildern. Die rechte Abbildung zeigt die verwendete Darstellung innerhalb des HMD. Zusätzlich zu den Kamera- und LiDAR-Daten werden die projizierte

Fahrspur, virtuelle Fahrzeugdimensionen und Räder, die Geschwindigkeit sowie die Gangwahl angezeigt.




Abbildung 5.3: Links: Fehlender Übergang zwischen vorderer und linker Kamera [171, S. 28]. Mitte: Verbesserter Übergang. Rechts: Vollständige Ansicht, dargestellt mit LiDAR-Daten als blaue Blöcke und Hilfselementen für die Fahrspur.

## Studiendesign

Vor Beginn der Studie werden die Probanden durch eine Präsentation in die Studie eingeführt und füllen im Anschluss einen demografischen Fragebogen aus. Um den Parcours kennenzulernen, fahren die Probanden zunächst als Beifahrer mit. Anschließend werden sie zufällig einer Startbedingung (Monitore oder HMD) und einer Startstation (3. oder 6.) zugewiesen. Nach einer Einweisung in das System haben die Probanden die Möglichkeit, auf einer separaten Strecke das System kennenzulernen, bevor sie den Testparcours unter beiden Bedingungen einmal durchfahren. Der Testparcours besteht aus sechs verschiedenen Manövern, die in zwei Teile aufgeteilt sind und alltägliche Fahraufgaben simulieren. Während einige Hindernisse so eng wie möglich passiert werden sollen, ohne sie zu berühren, erfordern andere Manöver das zentrale Durchfahren zwischen den Hindernissen. Um Schäden am Fahrzeug zu vermeiden, werden als Hindernisse gelbe Schaumstoffwürfel mit einer Kantenlänge von 40 cm verwendet. Die einzelnen Stationen sind:

1. Eng um eine Kurve fahren. Die Schaumstoffwürfel ragen 25 cm in die Fahrbahn hinein.
2. Nah an einem seitlichen Hindernis vorbeifahren.
3. An einer Linie halten.
4. Engen Fahrbahnwechsel durch Würfeltore.



Abbildung 5.4: Von links nach rechts: Fotos der verwendeten HMI [121, S. 14] und des Versuchsfahrzeugs an Station 3 und 4 sowie schematische Darstellung der Teststrecke

5. Ausweichen vor einem Hindernis. Dies simuliert das Warten hinter einem geparkten Auto, um ein anderes Auto passieren zu lassen.
6. Vorwärts einparken.

Für die objektive Messung werden die Abstände durch den Sicherheitsfahrer im Fahrzeug gemessen und notiert. Zusätzlich werden die Probanden aufgefordert die Abstände subjektiv einzuschätzen. Nach jeder Bedingung füllen die Probanden einen Fragebogen [171, S. 71] zur Erfassung der Selbsteinschätzung, Immersion und Workload aus.

### 5.1.4 Ergebnisse

Im folgenden Abschnitt werden nur die Kernergebnisse diskutiert; detaillierte Ergebnisse sind in Kapitel 6.4 sowie in [221] zu finden.

#### Objektive Daten

Aufgrund der Teilnehmerzahl von acht Probanden wird die Studie nur deskriptiv und nicht inferenzstatistisch ausgewertet [243, S. 224]. Die Durchschnittsgeschwindigkeit beträgt 1,6 m/s und die durchschnittliche Dauer pro Proband beträgt etwa 1,5 Stunden.

Die objektiven Ergebnisse lassen sich wie folgt zusammenfassen:

- In 90,6 % aller Fahrten treten Kollisionen auf. Die meisten ereignen sich bei Station 6 mit 48 % und Station 1 mit 27 %, unabhängig vom HMI. Beide Stationen erfordern Einsicht in den lateralen Seitenbereich des Fahrzeugs. Station 2 erfordert ebenfalls Einsicht in den Seitenbereich, jedoch können die Probanden hier direkt auf die Station zufahren und haben die Hindernisse länger im Sichtbereich.
- Der durchschnittliche frontale Abstand zur Haltelinie beträgt 0,73 m, wobei die meisten Probanden vor der Linie halten, anstatt dahinter.
- Hypothese  $H_1$  wird angenommen. Die Probanden können mit beiden HMI-Bedingungen alle Stationen ähnlich präzise bewältigen.

#### Subjektive Daten

Folgende Zusammenfassung ergibt sich für die subjektiven Ergebnisse:

- Der durchschnittliche Fehler bei der Selbsteinschätzung der Abstände beträgt mit dem HMD  $m_{\text{HMD}} = 8,5$  cm bei einer Standardabweichung von  $SD_{\text{HMD}} = 31,9$  cm.
- Die Selbsteinschätzung der Probanden zeigt, dass die Kollisionen bei Station 1 nicht erkannt wurden.
- Die subjektive Wahrnehmung zeigt eine ähnliche Realitätsnähe und Kontrollierbarkeit zwischen beiden HMI. Die Hypothese  $H_2$  wird angenommen.
- Der Workload, gemessen mit dem NASA-TLX-Fragebogen [244], zeigt in jeder Dimension keine relevanten Unterschiede. Die Hypothese  $H_3$  wird angenommen.

#### Diskussion

Die Studie ergab nur minimale Unterschiede zwischen der HMD- und der Monitor-HMI-Bedingung. Insgesamt hat die Studie deutliche Schwächen hervorgebracht; so kam es in mehr als 90 % aller Streckendurchläufe zu Kollisionen. Dies kann auf mehrere Faktoren zurückzuführen sein,

wie beispielsweise die begrenzte Übersichtlichkeit der HMI oder die fehlende Erfahrung der Probanden mit dem System und dem HMD aufgrund der kurzen Eingewöhnungsphase. Während und nach der Studie wurden die Probanden aufgefordert, ihre Gedanken mitzuteilen. Einige Probanden empfinden die Monitore als realitätsnäher, intuitiver und angenehmer. Das HMD wird am Anfang als schwierig empfunden, und einige Probanden gewöhnen sich erst nach längerer Zeit an das Gerät. Eine erweiterte Gewöhnungszeit könnte die Leistung beeinflussen. Die Verwendung von LiDAR-Blöcken wird von einigen Teilnehmern als störend empfunden, vor allem, wenn diese nicht passend mit den Kamerabildern überlagert sind. Gleichzeitig wird die Vogelperspektive der Belegungskarte im Monitor-HMI positiv erwähnt. Obwohl die Übergänge zwischen den Kamerabildern im Vergleich zum originalen HMI verbessert wurden, empfinden einige Probanden die verbleibenden Übergänge als störend.

## 5.2 Entwicklung des HMI

### 5.2.1 Ermittlung der Anforderungen

Die Ermittlung der Anforderungen ist ein zentraler Schritt im menschenzentrierten Gestaltungsprozess gemäß DIN EN ISO 9241-210. Ziel ist es, die Bedürfnisse, Erwartungen und Anforderungen der Nutzer sowie ihrer Aufgaben zu analysieren und zu spezifizieren. Dabei können verschiedene Methoden, wie Interviews, Beobachtungen, Workshops oder Literaturrecherche, eingesetzt werden. In diesem Abschnitt werden die Anforderungen an das HMI für die Teleoperation hinsichtlich der Sensordatendarstellung diskutiert. Dabei dienen sowohl die Ergebnisse der Voranalyse als auch die Literatur als Grundlage für die Identifikation der Anforderungen.

### Anforderungen aus der Literatur

Kettwich et al. [66, S. 6, 245] definieren sieben übergeordnete Anforderungen an das Teleoperations-HMI sowie an zukünftige Kontrollzentren. Diese umfassen notwendige Funktionen und Informationen zur Überwachung der Automatisierung, zur Bereitstellung von Störungsinformationen und zur Unterstützung bei der Störungsbehebung. Das HMI muss ein hohes Situationsbewusstsein für den RO ermöglichen. Zudem soll das HMI eine gute Usability und Akzeptanz aufweisen und in der Lage sein, die Aufmerksamkeit des Benutzers auf relevante Informationen zu lenken. Zuletzt darf die Arbeitsstation die mentalen und physischen Kapazitäten des Benutzers nicht überfordern und sollte nur eine mittlere Beanspruchung verursachen. Informationen sollten dort präsentiert werden, wo der Nutzer sie erwartet.

Adamides [246] listet eine Vielzahl unterschiedlicher Richtlinien für teleoperierte Roboter auf und unterteilt diese in acht Kategorien. Für diese Arbeit sind die Kategorien „Information Presentation“, „Robot Environment/Surroundings Awareness“ und „Cognitive Load“ relevant. Unter „Information Presentation“ werden unter anderem die Richtlinien aufgezählt, das Chassis des Roboters im HMI abzubilden und ein klares, einfaches sowie minimalistisches Design mit großen Fenstern zu verwenden. Unter „Robot Environment/Surroundings Awareness“ werden Richtlinien zur Darstellung der unmittelbaren Umgebung des Roboters und der Informationen des Videostreams in Relation zur Orientierung und Position des Roboters behandelt. Den Nutzern soll weiterhin erlaubt sein, die Perspektive anzupassen, und insgesamt soll die Aufmerksamkeit des Nutzers erhöht werden.

Drury et al. [247] untersuchen verschiedene Aspekte der Mensch-Maschine-Interaktion für kooperative Roboter. Sie stellen fest, dass die meisten Anomalien auf das Bewusstsein für die Mensch-Maschine-Interaktion zurückzuführen sind. Um dem entgegenzuwirken, stellen sie vier Richtlinien auf. Das HMI soll unter anderem dem RO eine Karte anzeigen, räumliche Informationen der nahen Umgebung darstellen und Sensorinformationen fusionieren, sodass der RO die Sensordaten nicht mental selbst fusionieren muss und dadurch die kognitive Belastung gesenkt wird.

Tener [172] führt eine umfangreiche Expertenbefragung mit acht Teilnehmern zum Thema Teleoperation von HAF durch. Die Probanden sind Experten sowohl auf dem Gebiet autonomer Fahrzeuge als auch der Teleoperation. Im Anschluss an die Befragung werden Fahrten durchgeführt, bei denen die Experten ein HAF mittels Remote Driving fernsteuern. Tener dokumentiert seine Beobachtungen sowohl aus der Befragung als auch aus den Versuchsfahrten und erstellt Empfehlungen für verschiedene Aspekte der Teleoperation. Für das HMI empfiehlt er unter anderem die Kalibrierung und das Stitching von überlappenden Videostreams, die Anzeige von Hilfselementen wie der zukünftigen Fahrspur sowie die Verwendung von Hinweisen zur Verbesserung der unzureichenden Tiefenwahrnehmung.

Laut Fong [248] soll die Benutzung von Interfaces zur Teleoperation schnell erlernbar und intuitiv sein und so gestaltet sein, dass das Training minimiert wird. Auch wenn die Arbeit sich hauptsächlich auf Anwendungen im Bergbau konzentriert, können weitere Anforderungen übertragen werden. So sollten die Anzeigen des Teleoperationssystems Sensordaten von verschiedenen Quellen darstellen können.

Pongrac fordert unter anderem die „Bereitstellung eines möglichst weiten Gesichtsfeldes“ [120, S. 289], einer „möglichst guten dreidimensionalen Darstellung“ [120, S. 289] und die „Vermeidung von Brüchen in der visuellen Darstellung“ [120, S. 289]. Ross [102] sieht die Verwendung eines weiten FOV ebenfalls als essentiell für ein gutes Situationsbewusstsein und fordert neben der Verwendung von Videostreams in möglichst hoher Qualität eine minimale Latenz zwischen dem RO und dem Fahrzeug.

Shen [119, S. 2] fordert eine angemessene Visualisierung der komplexen und dynamischen Betriebsumgebung während der Teleoperation von Fahrzeugen. Das HMI sollte den RO ein Gefühl der Immersion und Präsenz vermitteln, sodass sie die Umgebung des Fahrzeugs wahrnehmen können, als wären sie physisch vor Ort. Darüber hinaus sollte das System Echtzeit-Videostreaming und hochwertiges visuelles Feedback unterstützen. Zusätzlich sollte das Teleoperationssystem an verschiedene fahrzeuggebundene Plattformen anpassbar sein. Das System sollte in der Lage sein, sich mit verschiedenen Fahrzeugtypen zu integrieren, um unterschiedliche Anwendungen und Benutzeranforderungen zu berücksichtigen. [119]

### **Anforderungen aus der Voranalyse**

Durch die in Kapitel 5.1 durchgeführte Voranalyse können weiterhin Anforderungen an das HMI sowie das HAF abgeleitet werden. Eine zentrale Erkenntnis ist, dass die alleinige Erfassung des Nahbereichs durch LiDAR-Daten nicht ausreichend ist. Daher sollten auch Kameradaten zur Erfassung von Hindernissen genutzt werden. Kamera- und LiDAR-Daten sollten zudem gut übereinstimmen, um eine korrekte Hinderniserkennung und eine präzise Steuerung des Fahrzeugs zu ermöglichen.

Ein weiterer Aspekt ist die Minimierung störender Übergänge zwischen den verschiedenen Kameraperspektiven. Diese Übergänge wurden von den Probanden als irritierend und ablenkend



empfunden und sollten daher vermieden werden. Eine nahtlose Integration der Perspektiven ist daher wichtig, um den Fahrer nicht zu verwirren.

Die Probanden empfanden die Verwendung von Hilfslinien und einer Top-Down-Ansicht positiv, um die Positionierung des Fahrzeugs und die Hindernisse besser einschätzen zu können. Diese Funktionen sollten in zukünftigen HMI weiter ausgebaut werden.

Ein weiterer Aspekt, der bei der Verwendung von HMD zu berücksichtigen ist, betrifft die Eingewöhnungszeit. Die Studie hat gezeigt, dass die Probanden mit dem HMD angestrengter waren als mit herkömmlichen Bildschirmen. Dies könnte darauf zurückzuführen sein, dass die Verwendung eines HMD für den RO zunächst ungewohnt ist und eine Eingewöhnungszeit erfordert. Zukünftige HMI-Iterationen sollten daher auch darauf abzielen, diese Eingewöhnungszeit zu minimieren und dem RO eine Fahraufgabe mit einem angemessenen Workload zu ermöglichen.

Insgesamt sollten die Anforderungen an das HMI und das HAF darauf abzielen, eine präzise Hinderniserkennung, intuitive Bedienung und ein realitätsnahes Fahrerlebnis zu ermöglichen. Die Integration von Kamera- und LiDAR-Daten sowie die nahtlose Darstellung der verschiedenen Kameraperspektiven sind hierbei zentrale Elemente. Hilfslinien und eine Top-Down-Ansicht sollten als unterstützende Funktionen genutzt werden, um dem Fahrer eine präzisere und sicherere Steuerung des Fahrzeugs zu ermöglichen.

## 5.2.2 Umsetzung HMI

Im Folgenden wird die Umsetzung des HMI auf Basis der Anforderungen besprochen. Teile hiervon sind in [249] veröffentlicht und werden an dieser Stelle kurz zusammengefasst.

### Anpassung des Versuchsfahrzeugs an die Anforderungen

Die Sensorkonfiguration des Versuchsfahrzeugs (Abbildung 5.1) unterscheidet sich signifikant von der Sensorkonfiguration, die in HAF Verwendung findet (Abbildung 2.8). Um eine bessere Vergleichbarkeit zwischen dem Versuchsfahrzeug und HAF zu erreichen, werden auf Basis der Anforderungen verschiedene Modifikationen am Fahrzeug vorgenommen.

Vier Weitwinkelkameras mit einem HFOV von  $186^\circ$  und einem VFOV von  $104^\circ$  werden der Sensorkonfiguration des Fahrzeugs hinzugefügt: eine an jedem Stoßfänger sowie eine an jedem Spiegel. Auf diese Weise wird der Nahbereich des Fahrzeugs, einschließlich der Karosserie, durch Kameras erfasst. Die bereits vorhandenen vorderen Kameras wurden zusätzlich außerhalb des Fahrzeugs auf einem Dachträger montiert, sodass die A-Säule sich nicht mehr im Sichtfeld der Kameras befindet.

Darüber hinaus wurde die Sensorkonfiguration um ein Velodyne Puck [58] LiDAR erweitert. Dieser verfügt über 32 Ebenen, einen Öffnungswinkel von  $40^\circ$  vertikal und  $360^\circ$  horizontal und wurde um  $-8^\circ$  geneigt, vorne mittig auf dem Dachträger installiert. Dies gewährleistet eine ähnliche LiDAR-Sensorabdeckung, wie sie in vergleichbaren HAF vorliegt (Abbildung 2.8). Abbildung 5.5 zeigt den erweiterten Sichtbereich der neuen Sensorkonfiguration.

Durch diese Erweiterung verbessert sich die Umgebungswahrnehmung des Fahrzeugs, weil tote Winkel minimiert werden. Zudem lassen sich aufgrund der größeren Ähnlichkeit zu den Sensorsets von HAF die Ergebnisse dieser Arbeit besser auf das Zielanwendungsgebiet übertragen.




Abbildung 5.5: Erweitertes Sensorlayout des Audi Q7, ergänzt um Weitwinkelkameras und Velodyne Puck. Links: Vogelperspektive. Rechts: Seitenansicht.

## Softwarearchitektur

Die bestehende Softwarearchitektur des Fahrzeugs basiert auf dem „Automotive Data and Time-Triggered Framework“ (ADTF) von Elektrobit [250]. Aufgrund der gestiegenen Anforderungen, die aus den Ergebnissen der Voranalyse sowie aus den Anforderungen in Kapitel 5.2.1 hervorgehen, und aufgrund der neuen Sensorkonfiguration ist eine Refaktorisierung der gesamten Software notwendig.

Die neu hinzugefügten Sensoren verfügen bereits über Schnittstellen im moderneren Open-Source-Framework Robot-Operating-System (ROS) [251], die das Auslesen der Sensordaten ermöglichen. Im Gegensatz zu ADTF bietet ROS eine bessere Skalierbarkeit sowie ein breiteres Ökosystem von Tools und Algorithmen für die Verarbeitung und Analyse von Daten.

Eine Refaktorisierung der vorhandenen HMI-Software ist aufgrund der gestiegenen Anforderungen nicht praktikabel. Deshalb wird die Software auf einer neuen Architektur implementiert. Die neu implementierte Architektur folgt einer modularen Struktur und ermöglicht das einfache Hinzufügen verschiedener Komponenten. Abbildung 5.6 zeigt die verschiedenen Module und deren Subkomponenten.

Für diese Arbeit ist ausschließlich das OpenGL-Modul relevant. OpenGL [252] stellt eine tief liegende Schnittstelle zur Grafikkarte dar und ermöglicht die Anzeige grafischer Komponenten. Es wurde gewählt, weil es eine hohe Leistungsfähigkeit und Flexibilität bei der Erstellung sowohl von 2-D- als auch von 3-D-Visualisierungen bietet. Im Folgenden wird die Visualisierung der OpenGL-Module VideoStream und LiDAR-Daten beschrieben.

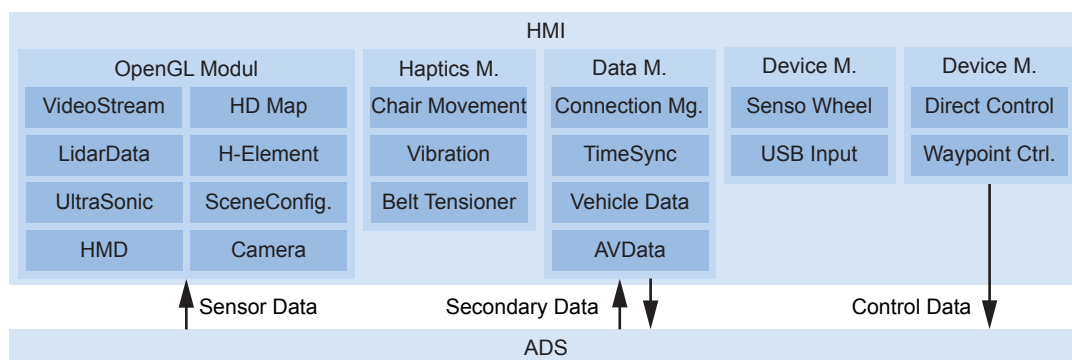


Abbildung 5.6: Softwarearchitektur des implementierten HMI und verschiedener Komponenten, adaptiert nach [249]

### 5.2.3 Videodatenvisualisierung

Zunächst werden die Grundlagen der Computergrafik zusammengefasst, weil die nachfolgenden Kapitel auf diesem Thema aufbauen.

#### Grundlagen Computergrafik

Die Visualisierung der Sensordaten basiert auf den in der Computergrafik üblichen Schritten der Modellierung, Texturierung, Transformation und des Renderings [253]. Diese Schritte ermöglichen es, dreidimensionale Szenen und Objekte zu erstellen und sie auf dem Bildschirm darzustellen.

Die Modellierung ist der erste Schritt bei der Erstellung von 2-D- oder 3-D-Objekten. Hierbei wird das Objekt in eine geometrische Struktur umgewandelt, wobei der grundlegende Baustein der Vertex ist. Eine Vertex beschreibt durch die Koordinaten  $v(x, y, z)$  einen dreidimensionalen Punkt im Raum. Objekte werden erstellt, indem einzelne Vertices zu Flächen verbunden werden. Die gebräuchlichste Form, um Vertices zu verbinden, sind Dreiecke. So können auch komplexe Geometrien modelliert werden, wobei nur die Oberflächen und nicht die Volumina modelliert werden. Das in Abbildung 5.7 dargestellte Rechteck wird durch die beiden Vertex-Gruppen  $\{v_0, v_1, v_2\}, \{v_1, v_2, v_3\}$  gebildet.

Die Texturierung ist der nächste Schritt bei der Erstellung von 3-D-Objekten. Hierzu werden Texturkoordinaten  $(u, v)$  verwendet, die auf die Position eines Pixels auf einer Textur verweisen. Bei einer Textur handelt es sich um ein Grafikobjekt, z. B. ein einzelnes Bild eines Videostreams. Jeder Pixel in einer Textur wird durch zwei Koordinaten beschrieben, die seine Position entlang der U- und V-Achsen angeben (Abbildung 5.7 Mitte). Um einen Zusammenhang zur Textur herzustellen, werden die Vertices um die Texturkoordinaten erweitert:  $v(x, y, z, u, v)$ . Die Grafikkarte führt automatisch die Interpolation der Textur auf die dreieckigen Flächen durch.

Die Transformation ist der Prozess, bei dem die Position, Größe und Ausrichtung des Objekts in der 3-D-Szene angepasst werden. Hierbei kommen Transformationen wie Translation, Skalierung und Rotation zum Einsatz, um das Objekt in der gewünschten Weise zu transformieren. Durch die Verwendung von Matrizen werden die Position, Größe und Ausrichtung des Objekts beschrieben. Schließlich wird das Objekt gerendert, indem es auf dem Bildschirm dargestellt wird. Dabei wird die 3-D-Szene auf eine 2-D-Bildschirmfläche projiziert. Die Perspektive und die Kameraeinstellungen werden dabei berücksichtigt. Die Perspektive legt fest, wie das Objekt von einem bestimmten Punkt im Raum aus gesehen wird. Die Kameraeinstellungen bestimmen die Position und Ausrichtung der Kamera, von der aus die Szene betrachtet wird. Mit einem HMD werden während des Renderings sowohl die Kameraausrichtung durch die Kopfposition des Nutzers als auch die Perspektive durch die Optik des HMD bestimmt.




Abbildung 5.7: Grundlagen der Computergrafik. Links: Modellierung. Mitte: Textur. Rechts: Transformation und Rendering.

## Darstellungsformen

Im vorherigen Kapitel wurden die Grundlagen der Objektmodellierung, der Texturierung und des Renderings besprochen. Das HMI wird maßgeblich durch die Wahl der geometrischen Modelle und der Kameraeinstellungen während des Renderings bestimmt. Eine zweidimensionale Darstellung der Videostreams erfolgt beispielsweise durch die Anordnung mehrerer Rechtecke und eine orthografische Projektion auf einen oder mehrere Bildschirme (Abbildung 5.8 links). Das gerenderte Bild kann dabei so vergrößert werden, dass es mehrere Monitore umfasst. Durch präzise Anordnung der Rechtecke kann ein Videostream pro Monitor angezeigt werden. Die meisten Teleoperationssysteme verwenden diese Art der Darstellung der Videodaten.

Hosseini [164] verwendet für die HMD-Visualisierung die in der Mitte der Abbildung 5.8 dargestellte Anordnung. Die Blickrichtung des RO bzw. die der virtuellen Kamera wird beispielhaft durch die grüne Pyramide angezeigt. Auf den Rechtecken wird jeweils ein Videostream angezeigt. Durch die alleinige Betrachtung der Videodaten ergibt sich kein Vorteil im Vergleich zu separaten Monitoren, weil die rechteckigen Flächen sich wie virtuelle Monitore in der dreidimensionalen Szene verhalten. Kot [163, S. 6] verwendete eine ähnliche Darstellung zur Visualisierung einer einzelnen Kamera und erweiterte diese um virtuelle Anzeigeelemente, wie z. B. eine Batterieanzeige.

Eine andere mögliche Darstellungsform ist in Abbildung 5.8 rechts gezeigt. Hier sind die Videostreamflächen als Würfel angeordnet. Befindet sich die virtuelle Kamera innerhalb des Würfels, kann die gesamte Umgebung um die Kamera durch Videodaten dargestellt werden. Hierdurch kann eine dreidimensionale und den Operator vollständig umschließende Szene geschaffen werden. Diese Darstellungsform ermöglicht eine realitätsnahe Erfahrung, weil der RO sich intuitiv umschauen kann. Jedoch ist diese Darstellungsform nur geeignet, wenn die sechs Kameras ebenfalls kreuzförmig angeordnet sind und sowohl einen HFOV als auch einen VFOV von  $90^\circ$  aufweisen. Andernfalls würde eine visuelle Diskontinuität an den Kanten des Würfels entstehen.




Abbildung 5.8: Links: Anordnung mehrerer Videostreams zur orthogonalen Projektion. Mitte: Anordnung nach Hosseini [164]. Rechts:  $360^\circ$  Anordnung.

Wie in Kapitel 2.1.6 gezeigt, verfolgen die extrinsischen und intrinsischen Kameraparameter primär den Zweck der HAF-Funktion. Es stellt sich die Frage, wie eine geeignete Darstellungsform aussieht und wie die verschiedenen Kameradaten des HAF kohärent auf dieser angezeigt werden können. Prinzipiell ist die Anzeige der Kameradaten auf jeder geometrischen Form möglich. Um glattere Übergänge und weniger visuelle Brüche zu erhalten, werden Formen mit runden Kanten gewählt. Abbildung 5.9 zeigt einige mögliche geometrische Formen, die zur Darstellung der Kameradaten verwendet werden können. Form (A) wird in verschiedenen Veröffentlichungen zur Visualisierung der Videodaten verwendet. Krückel et al. [170] projizieren fünf Videostreams von zentral angeordneten Kameras zur Visualisierung der Umgebung eines Minenroboters, und Bout [152] verwendet einen einzelnen Kamerastream von einer kommerziellen  $360^\circ$ -Kamera zur Visualisierung der Umgebung eines autonomen Shuttlebusses.




Abbildung 5.9: Mögliche geometrische Formen zur dreidimensionalen Darstellung der Kameradaten. Von links nach rechts: A: Kugel, B: Halbkugel und Scheibe, C: Offener Quader mit seitlich gerundeten Kanten, D: Geschlossener Quader mit gerundeten Kanten

Um die Videodaten auf den geometrischen Formen anzeigen zu können, muss jedem Vertex die entsprechenden Texturkoordinaten der jeweiligen Textur zugeordnet werden. Im Rahmen dieser Arbeit wurden zwei Methoden hierzu verwendet.

## UV-Berechnung auf Basis vorvernetzter Geometrien

Die erste Methode basiert auf der Modellierung der geometrischen Form in einem 3-D-Modellierungsprogramm (z. B. Blender). Der Vorteil der Verwendung einer separaten Software ist die einfache Vernetzung bzw. die Generierung der dreieckigen Flächen auf Basis der Vertices. Die Generierung der Texturkoordinaten erfolgt in drei Schritten:

Zunächst wird die Form innerhalb der 3-D-Software modelliert und kann anschließend als Geometrie-Datei (.obj) zwischengespeichert und in das HMI geladen werden. Hierzu wird die Open-Source-Bibliothek assimp [254] verwendet.

Im zweiten Schritt findet die Koordinatentransformation jedes Vertex vom Weltkoordinatensystem in das Kamerakoordinatensystem statt. Dies erfolgt durch eine Matrixmultiplikation jedes Vertex mit der Transformationsmatrix  $M$ , die auf Basis der Kameraposition  $v_p$ , der Blickrichtung der Kamera  $v_r$  und des Oben-Vektors  $v_o$  berechnet wird.

Im dritten Schritt wird auf Basis der intrinsischen Kameraparameter die Vertex auf das zweidimensionale Kamerabild transformiert (Abbildung 5.11 rechts). Zur Berechnung der intrinsischen

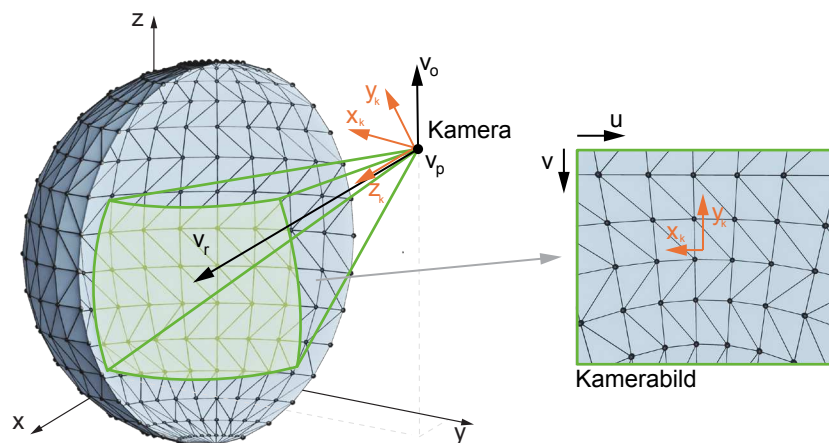


Abbildung 5.10: Berechnung der UV-Koordinaten mit vorvernetzten Geometrien. Links: Kamerasichtbereich. Rechts: Ergebnis der 3-D nach 2-D Projektion in das Kamerakoordinatensystem.

Kameraparameter ist eine Kalibrierung der Kamera notwendig. Hierzu werden mit Aufnahmen eines definierten Schachbrettmusters die intrinsischen Parameter der Kamera berechnet. Hierfür wird in dieser Arbeit die Methode nach Scaramuzza [255] und die dazugehörige Matlab- und C++-Bibliothek [256] verwendet. Der Vorteil dieser Methode liegt darin, dass verschiedene Kameramodelle, wie z. B. Fischaugen- und Teleobjektiv-Kameras, mit einem Modell parametrisiert werden können. Alle Kameras wurden mit einem Kalibrierungsfehler von  $<1$  px kalibriert.

## UV-Berechnung auf Basis variabler nicht vorvernetzter Geometrien

Die zweite Methode zur Berechnung der Texturkoordinaten wurde im Rahmen dieser Arbeit entwickelt und beruht auf der Verwendung variabler sowie nicht vorvernetzter Geometrien. Die geometrischen Formen werden in diesem Verfahren nicht mithilfe einer 3-D-Modellierungssoftware, sondern direkt innerhalb des entwickelten HMI erstellt. Als Eingänge werden ausschließlich die Vertex-Koordinaten und Kameraparameter verwendet.

Im ersten Schritt werden die Vertex-Koordinaten in das Kamera-Koordinatensystem transformiert und die Texturkoordinaten auf Basis der intrinsischen Kameraparameter berechnet. Vertices, die außerhalb des FOV der Kamera liegen, werden ausgefiltert. Um eine geometrische Fläche bilden zu können, müssen die einzelnen Vertices durch Dreiecke verbunden werden. Hierzu wird eine Implementierung des Delaunay-Algorithmus verwendet [257], die auf die Texturkoordinaten der Vertices angewandt wird. Der Delaunay-Algorithmus arbeitet auf einer Menge von Punkten auf der Ebene und generiert schrittweise Dreiecke, bis alle Punkte durch Dreiecke miteinander verbunden sind. Um eine Fläche zu bilden, werden im letzten Schritt die Informationen über die im zweidimensionalen Raum gefundenen Dreiecke auf die ursprüngliche dreidimensionale Geometrie übertragen.




Abbildung 5.11: Berechnung der UV-Koordinaten mit vorvernetzten Geometrien. Links: Kamerasichtbereich. Rechts: Ergebnis der 3-D nach 2-D Projektion in das Kamerakoordinatensystem.

Dieses Verfahren hat den Vorteil, Kameradaten ohne die notwendige Nutzung einer zusätzlichen 3-D-Software auf verschiedensten Geometrien effektiv abbilden zu können. Abbildung 5.14 zeigt das Ergebnis dieser Methode für die verschiedenen Kameras des verwendeten Versuchsfahrzeugs auf Basis der geometrischen Form B (Abbildung 5.9).





Abbildung 5.12: Ergebnis der vorgestellten Methode für die Frontkamera

## Übergang zwischen Videoflächen

Sowohl in der Studie von Tener [172, S. 13] als auch in der Arbeit von Meyersieck [171, S. 49] haben die Probanden die Übergänge zwischen den einzelnen Videostreams als störend empfunden. Um einen besseren Übergang zwischen den Streams zu erhalten, wird ein transparenter Verlauf mit einem linearen Gradienten an den Rändern des Streams hinzugefügt. Zu diesem Zweck werden die Vertex-Koordinaten um eine Transparenzkomponente  $\alpha$  erweitert:  $v(x, y, z, u, v, \alpha)$ . Diese wird als Funktion der Texturkoordinaten berechnet und muss jeweils in Abhängigkeit des FOV und der Auflösung der Kamera angepasst werden (Abbildung 5.13).

Abbildung 5.13: Transparenzfunktion  $\alpha(u, v)$ 

Wenn Transparenz verwendet wird, müssen die Objekte, um eine korrekte Darstellung zu gewährleisten, in einer definierten Reihenfolge gerendert werden. Dabei sollten die aus der Perspektive der OpenGL-Kamera hinteren Objekte zuerst gerendert werden, um sicherzustellen, dass die weiter vorne liegenden, transparenten Objekte korrekt dargestellt werden.

## Ergebnis der Videodatensvisualisierung

In Abbildung 5.14 wird das Ergebnis der in den vorherigen Kapiteln behandelten Themen mit realen Sensordaten dargestellt. Neben den Kameradaten wird die tatsächliche Geometrie des Fahrzeugs durch ein 3-D-Modell dargestellt. Deutlich zu erkennen ist, dass das gesamte Umfeld um das Fahrzeug durch die sechs Kameras vollständig erfasst wird. Dank der Kalibrierung und

Projektion werden die Umgebung und die Abstände von der Karosserie zu Objekten präzise angezeigt. Die nach hinten gerichtete Kamera wird als zweidimensionale Fläche mittig über der Frontkamera dargestellt.

Durch die Platzierung virtueller Kameras in der Szene können weitere Ansichten, wie beispielsweise eine Vogelperspektive, gerendert und als Textur gespeichert werden. Diese Textur kann anschließend direkt innerhalb des HMI verwendet und angezeigt werden (Abbildung 5.15).



Abbildung 5.14: Ergebnis der 3-D-Videodatenvisualisierung auf einem Monitor

Der Vorteil der Verwendung dieser Darstellungsmethode wird durch die Nutzung eines HMD verdeutlicht. Innerhalb des HMD kann sich der RO ähnlich wie im realen Fahrzeug umschauchen. Im realen Fahrzeug ist der Nahbereich direkt um das Fahrzeug selbst für einen realen Fahrer schwer einzusehen. Innerhalb des HMD kann die Karosserie transparent gerendert werden, was eine bessere Einsicht in den Nahbereich ermöglicht. Abbildung 5.15 zeigt einen Bildschirmmausschnitt aus dem HMD. Zusätzlich wurden Augmented-Reality-Elemente eingesetzt, um die realen Eingabegeräte leichter mit aufgesetzter Brille finden und betätigen zu können.



Abbildung 5.15: Ergebnis der 3-D-Visualisierung innerhalb eines HMD für das linke und rechte Auge



## 5.2.4 LiDAR-Daten Visualisierung

Im vorangegangenen Kapitel wurde die Visualisierung der Kameradaten erläutert. Neben den Kameradaten können dem Operator auch die LiDAR-Daten des Fahrzeugs angezeigt werden. In den bisherigen Veröffentlichungen werden verschiedene Möglichkeiten präsentiert, die LiDAR-Daten darzustellen. In der Robotik [258] werden LiDAR-Daten häufig verwendet, um Karten der Umgebung zu erstellen und dem RO als Orientierungshilfe anzuzeigen. Für HAF verwenden Hosseini [164] und Meyersieck [171] eine Vogelperspektive sowie blaue virtuelle Würfel in der dreidimensionalen Darstellung innerhalb des HMD, um die Tiefenwahrnehmung zu verbessern (Abbildung 5.3). Die Ergebnisse der Vorstudie zeigen, dass eine fehlende Übereinstimmung der LiDAR- und Kameradaten den Operator verwirren kann. Aus den Anforderungen geht hervor, dass die Sensordaten fusioniert werden sollten, um die mentale Belastung des Operators zu reduzieren. Dieses Kapitel behandelt daher die Fusion und Visualisierung der LiDAR-Daten mit den Kameradaten.

Am Fahrzeug sind, wie in Kapitel 5.2.2 beschrieben, zwei verschiedene LiDAR-Sensormodelle verbaut, die hierzu genutzt werden können. Das erste Modell ist der Sick LMS 291 [259], mit einer Scan-Ebene und einem horizontalen Sichtfeld von 180° HFOV, einer Winkelauflösung von 1° und einer Frequenz von 10 Hz, der sowohl vorne als auch hinten auf Höhe der Stoßstange montiert ist. Der zweite LiDAR-Sensor ist der Velodyne VLP-32C [58], mit 32 Scan-Ebenen, einem vertikalen Öffnungswinkel von 40° VFOV, einem horizontalen Öffnungswinkel von 360° HFOV, einer Winkelauflösung von 0,3° und einer Frequenz von 10 Hz. Dieser Sensor ist mittig über der Windschutzscheibe montiert, wie in Abbildung 5.5 dargestellt. Im Folgenden wird die Einbindung beider Sensormodelle in das HMI beschrieben.

### Einbindung des Sick LMS 291

Die Sensordaten werden über eine serielle Schnittstelle an den Fahrzeugrechner übermittelt und anschließend per LTE an den Operatorarbeitsplatz übertragen. Aufgrund der geringen Datenrate von 7,2 kB/s ist eine Komprimierung der Sensordaten für diesen Sensortyp nicht notwendig. Die Visualisierung der Daten kann auf unterschiedliche Arten erfolgen (Tabelle 5.1). Hosseini [164] verwendet sowohl eine Vogelperspektive als auch Marker in Form von blauen Würfeln innerhalb des HMD. Im Rahmen dieser Arbeit wurden zwei Möglichkeiten, sowohl für den Monitor als auch

Tabelle 5.1: LiDAR Option

Quelle	HMI	Gerät	Darstellungsform
Hosseini [164]	2D	Monitor	Vogelperspektive
Hosseini [164]	3D	HMD	Marker (Blaue Würfel)
	➤	3D HMD	LiDAR-Kamera Fusion
	➤	3D Monitor	Marker (Rote Punkte)

für das HMD, zur Visualisierung der LiDAR-Daten des Sick 1-Ebenen-LiDAR entwickelt. Die erste Möglichkeit besteht darin, die LiDAR-Daten als rote Punkte auf dem 3-D-HMI anzuzeigen. Die zweite Möglichkeit ist eine Fusion von Kamera- und LiDAR-Daten für das HMD-HMI, bei der die Videoflächen auf Basis der LiDAR-Daten verformt werden.

Um die LiDAR-Daten im HMI visualisieren zu können, werden die Rohdaten des Sensors zunächst in eine geeignete Form gebracht. Hierbei werden die Messwerte des LiDAR in eine Punktwolke umgewandelt, die dann zur Darstellung innerhalb des HMI verwendet werden kann.

Damit die LiDAR-Daten im HMI korrekt dargestellt werden, ist es notwendig, die extrinsischen Parameter des Lidars zu bestimmen. Diese Parameter beschreiben die räumliche Ausrichtung des LiDAR relativ zum Fahrzeug und sind daher entscheidend für die korrekte Positionierung der LiDAR-Daten im HMI. Zur Bestimmung dieser Parameter wird der LiDAR kalibriert, indem Referenzpunkte im Raum erfasst werden. Auf Basis dieser Referenzpunkte können die extrinsischen Parameter berechnet werden.

Nachdem die LiDAR-Daten in eine Punktwolke umgewandelt und die extrinsischen Parameter bestimmt worden sind, werden die Daten im HMI dargestellt. Hierbei ist es wichtig, dass die LiDAR-Daten korrekt relativ zu den Kameradaten und zu der Karosserie angezeigt werden, um logische Brüche zu vermeiden. Die 3-D-Punktwolke wird daher durch Translation und Rotation an der korrekten örtlichen Position innerhalb des HMI platziert.

Die LiDAR-Daten werden in Echtzeit als rote Punkte dargestellt, um eine intuitive Interpretation der Daten durch den Operator zu ermöglichen. Die Farbe Rot wird im Kontext von Laserdistanzmessungen häufig verwendet und ist daher intuitiv verständlich. Abbildung 5.16 zeigt die Darstellung der LiDAR-Daten in einer engen Fahrsituation.



Abbildung 5.16: Visualisierung der LiDAR-Daten als Marker innerhalb des 3-D HMI. Zur Verbesserung der Sichtbarkeit um das Fahrzeug werden Chassisteile ausgeblendet.

Die zweite Möglichkeit zur Darstellung der Lidar-Daten besteht in der Fusion mit den Kameradaten, um eine realitätsgetreuere Darstellung der Umgebung des Fahrzeugs zu ermöglichen. Sie baut auf der Abschlussarbeit von Franke [260] auf. Hierbei werden die Videoflächen auf Basis der Lidar-Daten verformt, um eine genaue räumliche Beziehung zwischen den Kameradaten und den Lidar-Daten zu erreichen.

Um die Lidar-Daten für die Fusion mit den Kameradaten vorzubereiten, werden die Rohdaten des Lidars zunächst in eine Punktwolke umgewandelt und in eine für die Darstellung geeignete Form gebracht. Basierend auf dieser Punktwolke wird ein Vertex-Mesh erzeugt, das als Grundlage für die Darstellung der Kameradaten dient.

Das Vertex-Mesh wird dann auf Basis der Lidar-Daten umgeformt, um eine genaue räumliche Beziehung zwischen den Kameradaten und den Lidar-Daten zu erreichen. Hierbei werden die Punkte des Vertex-Meshs so verschoben und gedreht, dass sie der Form der Umgebung entsprechen, wie sie durch die Lidar-Daten erfasst wurde (Abbildung 5.17 oben).

Die Kameradaten werden dann auf das umgeformte Vertex-Mesh projiziert, um eine realitätsgetreue Darstellung der Umgebung des Fahrzeugs zu ermöglichen (Abbildung 5.17 unten). Durch die Fusion der Kamera- und Lidar-Daten kann eine genaue räumliche Beziehung zwischen den Daten hergestellt werden, was eine präzisere und potenziell intuitivere Darstellung der Umgebung des Fahrzeugs ermöglicht.




Abbildung 5.17: Oben: Auf Basis der LiDAR-Daten vernetztes Vertex-Mesh. Unten: Auf das Mesh projizierte Kameradaten. [260]

## Einbindung Velodyne VLP-32C

Der Velodyne VLP-32C hat einen Messbereich von 32 Reihen übereinander, wobei er alle  $2,304 \mu\text{s}$  zwei Punkte vermessen kann. Der LiDAR kann somit etwa 578.703,7 Punkte pro Sekunde vermessen und eine deutlich höhere räumliche Auflösung bereitstellen als der Sick LiDAR. Weiterhin kann der horizontale Öffnungswinkel des LiDAR beliebig eingestellt werden, während die Winkelauflösung konstant bleibt und nur proportional zur einstellbaren Rotationsgeschwindigkeit variiert.

Die Daten werden über UDP an den Fahrzeugrechner übertragen, wobei jedes UDP-Paket 32 Messwerte einer vertikalen Messspalte enthält. Der Header jedes UDP-Pakets enthält neben weiteren Informationen den Azimutwinkel der gemessenen Spalte. Die 32 Punkte werden in unterschiedlichen vertikalen Winkeln vermessen, die anhand einer Kalibrierungstabelle bestimmt werden können [58].

Um die effiziente Übertragung von LiDAR-Daten an das HMI zu gewährleisten, werden lediglich relevante Informationen per UDP übertragen. Durch die definierte Reihenfolge der Punkte innerhalb des UDP-Pakets kann die Datenrate erheblich reduziert werden. Da die Punkte im Kugelkoordinatensystem vorliegen und der Azimut sowie der vertikale Winkel bekannt sind, wird

nur die gemessene Entfernung pro Punkt übertragen. Eine Komprimierung der Daten ist somit für die Übertragung eines einzelnen Sensors dieses Modells nicht notwendig. Für Sensoren mit höheren Auflösungen existieren Verfahren, die eine Komprimierung von LiDAR-Daten und somit die Übertragung höherer Datenraten über LTE ermöglichen [261].

Innerhalb des HMI erfolgt die Speicherung der Entfernungsdaten in einer Listenstruktur, die durch einen Vertex-Shader auf der Grafikkarte des Systems verarbeitet wird. Hierbei wird eine Transformation der Daten aus dem Kugelkoordinatensystem in das kartesische Koordinatensystem des Fahrzeugs durchgeführt. Ein Shader ist eine spezielle Funktion, die für jedes Element eines Objekts simultan auf der Grafikkarte ausgeführt wird. Abbildung 5.18 oben zeigt das Ergebnis nach der Datenübertragung, wobei die Farbe jedes Vertex die Reflexionsintensität des jeweiligen Messpunkts widerspiegelt.

Zur Fusion der Kamera- und LiDAR-Daten wird eine ähnliche Methode wie in Kapitel 5.2.3 verwendet. Zunächst werden die einzelnen Vertices durch Dreiecke zu einem zusammenhängenden Netz verbunden. Aufgrund der geordneten, matrixähnlichen Struktur der LiDAR-Vertices können die zugehörigen Vertices für jedes Dreieck sofort bestimmt werden. Abbildung 5.18 zeigt die zu einer Fläche vernetzten Vertices. Im nächsten Schritt werden für jeden Vertex die




Abbildung 5.18: Links: Unvernetzte Rohdaten des Velodyne LiDAR-Sensors. Rechts: Vernetzte Geometrie auf Basis der LiDAR-Daten. [262]

zugehörigen Texturkoordinaten berechnet. Befindet sich die Kamera an der gleichen Position wie der LiDAR-Sensor, kann diese Berechnung einmalig erfolgen, weil die Texturkoordinaten nicht von der gemessenen Entfernung abhängen. Befindet sich die Kamera an einem anderen Ort, müssen die Texturkoordinaten für jede neu erhaltene LiDAR-Messung neu berechnet werden. Abbildung 5.19 zeigt das Ergebnis für eine Szene. Innerhalb des HMD kann die Szene durch das stereoskopische Sehen dreidimensional wahrgenommen werden.




Abbildung 5.19: Links: 2-D-Kamerabild. Rechts: Fusion der Kamera- und LiDAR-Daten. [262]

# 6 Ergebnisse

Die vorherigen Kapitel beschreiben die Erstellung verschiedener HMI-Varianten für die direkte Teleoperation von HAF. In diesem Kapitel werden die HMI zur Beantwortung der Forschungsfragen evaluiert. Hierzu werden zwei Studien durchgeführt. Die erste Studie hat den Fokus auf dem Einfluss der Anzeigergeräte und Darstellungsformen auf das Situationsbewusstsein in alltäglichen Verkehrssituationen. Die zweite Studie fokussiert sich auf die präzise Steuerung des Fahrzeugs in engen Situationen und somit auf die Tiefenwahrnehmung des Operators und die Fusion der LiDAR-Daten.

## 6.1 Design Studie 1: Situationsbewusstsein, Anzeigergeräte und Darstellungsformen

Die folgende Studie baut auf den Studienarbeiten von Putz [263] und Guggenmoss [264] auf. Die Ergebnisse über die Auswirkungen der Qualität, die aus der Analyse mit konventionellen Modellen entstanden sind, wurden teilweise in [265] veröffentlicht.

### 6.1.1 Forschungsziele der Studie

In dieser Studie werden die Forschungsziele im Kontext der übergeordneten Forschungsfragen formuliert: Wie sieht ein geeignetes Anzeigekonzept für die direkte Steuerung von automatisierten Fahrzeugen aus (F1)? Welche visuellen Darstellungsformen und Anzeigergeräte sind geeignet, um ein angemessenes Level an Situationsbewusstsein zu erreichen (F1-A)? Wie beeinflusst die Qualität der Kameradaten das Situationsbewusstsein der Benutzer des Systems (F1-C)? Und wie wirkt sich eine zunehmende Systemerfahrung auf die Mensch-Maschine-Interaktion aus (F2)? Um diese Fragen zu beantworten, wird eine umfassende Studie durchgeführt, die den Einfluss verschiedener HMI auf Kennwerte des teleoperierten Fahrens analysiert.

Hierzu werden verschiedene HMI in der Studie verglichen: ein herkömmliches Teleoperator-Interface, bestehend aus drei Monitoren mit monoskopischer Ansicht, eines mit drei Monitoren und dreidimensionaler Ansicht, und ein HMD mit dreidimensionaler Ansicht. Die Studie zielt darauf ab, die Auswirkungen dieser Interfaces auf das Situationsbewusstsein, die Usability, den Workload, die Immersion und die Presence sowohl quantitativ als auch qualitativ zu analysieren.

Darüber hinaus wird die Lernförderlichkeit der verschiedenen HMI untersucht, um festzustellen, ob eines der Designs Vorteile hinsichtlich der Erlernbarkeit und Intuitivität bietet. Um die Veränderungen in den abhängigen Variablen im Laufe der Zeit bewerten zu können, findet die Studie über einen Zeitraum von vier Wochen statt.

Um realitätsnahe Bedingungen zu schaffen, werden Simulationsumgebungen und aufgezeichnete Verkehrsszenen aus dem realen Straßenverkehr verwendet. Diese ermöglichen es, das

Situationsbewusstsein der Probanden in einem standardisierten und dennoch realitätsnahen Kontext zu testen. Um den Einfluss der Qualität auf das Situationsbewusstsein in Abhängigkeit der unabhängigen Variablen zu untersuchen, werden die aufgezeichneten Verkehrsszenen in der Qualität variiert.

Durch die Untersuchung der genannten Forschungsziele soll ein besseres Verständnis dafür entwickelt werden, welches Anzeigekonzept für die direkte Steuerung von automatisierten Fahrzeugen geeignet ist und welchen Einfluss visuelle Darstellungsformen und Anzeigegeräte auf das Level des Situationsbewusstseins haben.

### 6.1.2 Studienaufbau

#### Hypothesen

In diesem Kapitel werden die Hypothesen der Studie vorgestellt, die sich auf die Untersuchung des Einflusses der verschiedenen HMI auf das Situationsbewusstsein, die subjektive Bewertung der Ansicht, die Usability, den Workload, die Immersion und die Presence konzentrieren. Darüber hinaus soll auch die Lernförderlichkeit der Interfaces in Bezug auf diese Faktoren analysiert werden. Die Hypothesen bauen auf den Überlegungen des vorherigen Kapitels auf und dienen als Grundlage für die empirische Untersuchung, um die Forschungsfragen zu beantworten und mögliche Zusammenhänge zwischen den verschiedenen Interfaces und den genannten Faktoren zu identifizieren.

- Abhängige Variablen
  - A. Erkannte Verkehrsteilnehmer
  - B. Erkannte Verkehrsschilder
  - C. Geschätzte Geschwindigkeit
  - D. Geschätzte Position auf der Spur
  - E. Vorhersage einer sicheren Weiterfahrt
  - F. Usability
  - G. Workload
  - H. Immersion
  - I. Sicherheitsempfinden
- Unabhängige Variablen
  1. HMI
  2. Qualität
  3. Nutzungshäufigkeit des Interfaces

Die Hypothesen ergeben sich aus der Permutation der abhängigen und unabhängigen Variablen, z. B.  $H_{A,1}$ : Das HMI hat keinen Einfluss auf die erkannten Verkehrsteilnehmer:

- $H_{\alpha,\beta}$ :  $\{1,2,3\}$  hat keinen Einfluss auf  $\{A,\dots,I\}$

#### Messeinrichtung und HMI Auswahl

Der Versuch findet in den Räumlichkeiten des Lehrstuhls für Fahrzeugtechnik an der Technischen Universität München statt und verwendet zur Datenaufzeichnung das in Kapitel 5.2.2 vorgestellte Versuchsfahrzeug. Der Operator-Arbeitsplatz befindet sich in einer Versuchshalle des Lehrstuhls und besteht aus einem Fahrersitz, einem Lenkrad und einer Pedalerie. Dieser ist in Abbildung 6.1 dargestellt. Die Videobilder, die von den Kameras auf dem Versuchsfahrzeug aufgenommen

werden, werden entweder auf drei 55-Zoll großen Bildschirmen (55"LG660S) oder mit einer HTC-Vive-Pro HMD, je nach Versuchsgruppe, dargestellt. Um die Anzahl der unabhängigen Variablen zu reduzieren, wird durch Experten des Lehrstuhls eine Vorauswahl aus den in Kapitel 5.2.3 vorgestellten HMI getroffen. Die unterschiedlichen HMI sind:

1. Monitor 2-D - Konventionelles HMI
2. Monitor 3-D - Geometrische Form (B)
3. HMD - Geometrische Form (B)

Es wurde die geometrische Form (B) gewählt, weil diese aufgrund der sphärischen Form konsistente Übergänge zwischen den Videostreams ermöglicht, aber dennoch den Boden als realistisch flach darstellt. Alle HMI sind in Abbildung 6.1 dargestellt. Obwohl das Versuchsfahrzeug über acht verschiedene Kameras verfügt, werden nur vier Kameras zur Darstellung der Szene verwendet. Hierbei handelt es sich um die linke und rechte Fischaugen-Kamera sowie die nach vorne und hinten gerichteten Kameras mit 90° HFOV. Die Kameraanzahl wurde reduziert, weil die vier Kameras für die Studie zur Beantwortung der Forschungsfragen ausreichend sind. Zudem wurden explizit Fischaugen-Kameras gewählt, um insbesondere beim Monitor 2-D HMI die Auswirkungen der starken Verzerrung auf die abhängigen Variablen feststellen zu können. Durch die Projektion im Monitor 3-D und HMD HMI ist keine Verzerrung durch die Fischaugen-Kameras in diesen HMI sichtbar. Auf die Anzeige der Vogelperspektive wurde in dieser Studie verzichtet, weil diese immer in der gleichen Ansichtsart, unabhängig vom HMI, angezeigt wird und nur in speziellen Verkehrssituationen relevant ist.




Abbildung 6.1: Oben links: Operator-Arbeitsplatz. Oben rechts: Monitor 2-D. Unten links: Monitor 3-D. Unten rechts: HMD.

## Szenen zur Evaluierung des Situationsbewusstseins

Das Studiendesign beinhaltet die Wiedergabe von aufgezeichneten realen Fahrscenen. Hierzu werden mit dem Versuchsfahrzeug verschiedene Situationen aus dem Alltag aufgenommen. Die Daten werden ausschließlich für diese Studie verwendet und nicht veröffentlicht. Die aufgenommenen Szenen werden geschnitten und jeweils in niedriger und hoher Qualität gespeichert. Das 4G-Netz ist innerstädtisch flächendeckend verfügbar. Basierend auf diesen Daten werden für die niedrige Qualität Werte von 5 Mb/s und für die hohe Qualität 15 Mb/s gewählt. Von diesen

Werten werden 25% für die rechte und linke, 35% für die Front- und 15% für die Rückfahrkamera verwendet.

Insgesamt werden 24 kurze Szenen und vier lange Szenen aufgezeichnet. Eine detaillierte Beschreibung der einzelnen Szenen ist in [264] zu finden. Die kurzen Szenen haben eine durchschnittliche Dauer von 25 Sekunden und werden genutzt, um das Situationsbewusstsein der Probanden abzufragen. Studien zu Fahrerassistenzfunktionen haben gezeigt, dass 10-12 Sekunden ausreichend sind, um Situationsbewusstsein aufzubauen [266, S. 648, 267, 268, S. 214]. Nach jeder Szene werden den Probanden Fragen gestellt, um die drei Ebenen des Situationsbewusstseins zu bewerten. In den Szenen sind bis zu sieben relevante Verkehrsteilnehmer zu sehen, um die menschliche Informationsgrenze des Kurzzeitgedächtnisses von  $7 \pm 2$  Informationen nicht zu überschreiten [269, S. 29]. Die Szenen enden nicht mit dem Anhalten oder Parken des Fahrzeugs an einem sicheren Ort, um eine Vorhersage des zukünftigen Geschehens (Situationsbewusstsein Ebene 3) zu ermöglichen.

Zusätzlich zu den 24 Situationsbewusstsein Szenen werden den Probanden insgesamt vier Szenen gezeigt, die sich mit einem Anwendungsfall des autonomen Fahrens befassen. Dabei handelt es sich um Situationen, in denen ein autonom fahrendes Auto potenziell Schwierigkeiten bei der Entscheidungsfindung haben könnte. Die vier Szenen werden zufällig über die vier Versuchstage verteilt gezeigt.

Die vier längeren Szenen sind im Durchschnitt 180 Sekunden lang und werden zum Ende des Versuchstages gezeigt, um den Probanden ausreichend Zeit zu geben, sich intensiver mit dem HMI auseinanderzusetzen. [263, 264]

### **Versuchsdesign**

Das Ziel der Studie und die abgeleiteten Hypothesen führen zu einem gemischten Design mit mehreren Faktorstufen. Der Faktor Interface-Gruppe mit den drei Faktorstufen HMD, Monitor-Sphere und Monitor-Flat stellt den Gruppenfaktor dar und wird anhand der Angaben im demografischen Fragebogen den Probandengruppen zugeordnet. Das genaue Vorgehen wird in der Probandenkonstellation erläutert. Der Faktor Tag mit den vier Stufen Tag eins, Tag zwei, Tag drei und Tag vier stellt den ersten Messwiederholungsfaktor dar. Der Faktor Qualität mit den Stufen niedrig und hoch stellt den zweiten Messfaktor dar. Es werden insgesamt drei unabhängige Variablen betrachtet. Das Ziel der Analyse ist es, den Einfluss der unabhängigen Variablen Gruppe, Termin und Qualität sowie deren Interaktion auf die abhängigen Variablen Situationsbewusstsein, Usability, Workload, Immersion und Sicherheitsempfinden zu untersuchen.

Zu Beginn jedes Versuchstags absolvieren die Probanden vier Fahrten in der Simulation, die in dieser Arbeit nicht analysiert werden. Anschließend werden sieben Szenen, die im realen Straßenverkehr aufgezeichnet wurden, separat betrachtet und analysiert. Um mögliche Sequenzeffekte zu vermeiden, werden an jedem Versuchstag andere Szenen gezeigt. Die insgesamt 24 Situationsbewusstsein Szenen werden in Gruppen zu je sieben Szenen aufgeteilt, wobei in jeder Interface-Gruppe an jedem Versuchstag dieselben Szenen gezeigt werden. Die ersten Probanden jeder Gruppe sehen an jedem Versuchstag dieselben sieben Szenen, während die zweiten Probanden jeweils eine andere Sequenz erhalten. Nach diesem Schema werden die Szenen permutiert. Zum Abschluss jedes Versuchstages wird den Probanden eine längere Szene gezeigt. Während dieser werden die Probanden aufgefordert, sich auf das HMI zu konzentrieren und gemäß der Think-Aloud-Methode [270, S. 2] ihre Gedanken mitzuteilen.



Im Anschluss füllen die Probanden einen Abschlussfragebogen aus. Der genaue Ablauf für die vier Versuchstage ist in Abbildung 6.2 dargestellt.

Termin 1	Termin 2	Termin 3	Termin 4
Einführung			
4 Fahrten Simulation	4 Fahrten Simulation	4 Fahrten Simulation	4 Fahrten Simulation
7 Szenen mit Fragebogen	7 Szenen mit Fragebogen	7 Szenen mit Fragebogen	7 Szenen mit Fragebogen
Lange Szene	Lange Szene	Lange Szene	Lange Szene
Abschlussfragebogen	Abschlussfragebogen	Abschlussfragebogen	Abschlussfragebogen
			Realfahrt und Vergleich

Abbildung 6.2: Versuchsablauf

## Versuchsablauf

Um die Objektivität des Versuchs zu gewährleisten, wird eine Checkliste für jeden Termin erstellt. Der Versuch findet einmal pro Woche am gleichen Wochentag statt und umfasst insgesamt vier Termine. Der erste Termin dauert etwa 45 Minuten und die folgenden Termine etwa 30 Minuten pro Proband. Zu Beginn jeder Sitzung wird der Proband begrüßt und eine Einführungspräsentation über die Teleoperation und die grundlegenden Funktionsweisen des Testfahrzeugs gezeigt. Die Probanden füllen anschließend eine Datenschutzerklärung aus und werden über den genauen Ablauf des Versuchs informiert. Während des gesamten Versuchs werden Tonaufnahmen gemacht, und die Probanden werden aufgefordert, ihre Gedanken und Eindrücke laut auszusprechen. Vor Beginn des eigentlichen Versuchs wird den Probanden erklärt, wie die jeweilige Ansicht aus den aufgezeichneten Daten der Kameras zusammengesetzt wird. Den Probanden der HMD-Gruppe werden anschließend individuell eingestellte VR-Brillen ausgehändigt, wobei darauf hingewiesen wird, bei Anzeichen von Übelkeit den Versuchsleiter zu informieren.

Eine erste Phase des Versuchs beinhaltet vier verschiedene Verkehrsszenarien, die der Proband in der Fahrsimulationssoftware SILAB [272] absolviert. Die Szenarien werden zu Beginn jedes Versuchstages in zufälliger Reihenfolge abgefahren, nach einer kurzen Einführungsfahrt, um das Fahren in der Simulation zu verinnerlichen. Die Szenarien umfassen unterschiedliche Verkehrsbedingungen, Wetter- und Lichtverhältnisse sowie Schwierigkeitsgrade und sind in einem Leitfaden mit genauen Fahrhinweisen zusammengefasst. Der Proband wird daran erinnert, die Straßenverkehrsordnung zu beachten, auf Verkehrsschilder zu achten und die Geschwindigkeitsbegrenzung von 30 km/h einzuhalten.

Vor dem zweiten Teil des Versuchs wird den Probanden erneut erklärt, dass sie die Rolle eines RO einnehmen. Im zweiten Teil werden sieben Verkehrsszenen gezeigt, die im realen Verkehr mit dem Testfahrzeug aufgezeichnet wurden. Die Szenen werden in hoher und niedriger Qualität gezeigt, ohne dass die Probanden darauf hingewiesen werden. Der Proband soll die Szenen aufmerksam verfolgen und nach jeder Szene Fragen zur Messung des Situationsbewusstseins beantworten. Zur Einführung wird eine aufgezeichnete Szene gezeigt, in der die Geschwindigkeit des Fahrzeugs dargestellt wird. Alle anderen Szenen enthalten keine Geschwindigkeitsanzeige. Neben den Verkehrsteilnehmern und Schildern wird die gefahrene Geschwindigkeit und die Position auf der Fahrspur geschätzt. Zudem wird subjektiv bewertet, wie sicher die Probanden sich mit diesem HMI gefühlt hätten, wenn es sich um eine reale Verkehrssituation gehandelt hätte. Die Probanden geben ihre Antworten direkt in das Umfrageprogramm LimeSurvey [273]

ein. Nach den sieben Verkehrsszenen wird eine längere Aufzeichnung gezeigt, die ca. 5 Minuten dauert. Während dieser Szene werden die Probanden gebeten, sich nicht auf das Verkehrsgeschehen, sondern auf das HMI zu konzentrieren und dazu Feedback zu geben. Zuletzt wird der Abschlussfragebogen selbstständig am PC ausgefüllt.

Nach dem vierten und letzten Termin des Versuchs erhalten die Probanden die Möglichkeit, eine ausgewählte Szene jeweils dreimal mit allen drei HMI zu betrachten. Zunächst wird die Szene mit dem HMI ihrer Gruppe gezeigt, danach in zufälliger Reihenfolge mit den beiden anderen HMI. Die Probanden werden erneut darauf hingewiesen, ihre Gedanken und Meinungen zu äußern und die HMI zu vergleichen. Abschließend sollen sie das aus ihrer Sicht geeignetste HMI für das teleoperierte Fahren auswählen.

Darüber hinaus haben die Probanden die Gelegenheit, das Testfahrzeug an einem zusätzlichen Termin auf dem Gelände der Technischen Universität München mit allen drei HMI in der Realität fernzusteuern. Jeder Proband fährt eine Runde à 700 m mit dem HMD, dem M2D und dem M3D HMI. Um die Fahrt für die Probanden sicherer und einfacher zu gestalten, werden bei den HMI die Geschwindigkeitsanzeige und die prädiizierte Fahrspur angezeigt.

### **Probandenkollektiv**

Jeder Proband erhält vor dem Versuch einen Fragebogen [264], der neben demografischen Angaben auch Fragen zur Fahrerfahrung und Erfahrung mit Fahrsimulator-Studien beinhaltet. Anhand der Antworten auf den Fragebogen wird jeder Proband einer HMI-Gruppe zugeordnet. Dabei wird aufgrund der geringen Stichprobengröße das Matching-Prinzip verwendet. Um Drillings mit ähnlichen Angaben zu bilden, werden die jährliche Fahrtstrecke und die Dauer des Führerscheinbesitzes berücksichtigt. Jeder Proband aus einer Drilling-Gruppe wird dann einer HMI-Gruppe zugeordnet, wobei die Zuweisung randomisiert erfolgt. Allerdings werden Probanden, die im Fragebogen angeben, anfällig für Übelkeit bei VR-Brillen zu sein, nicht der HMD-Gruppe zugewiesen.

Die Probanden werden hauptsächlich über persönliche Kontakte der Versuchsleiter, persönliches Ansprechen oder Aushänge auf dem Gelände der Technischen Universität München rekrutiert. Jede volljährige Person mit Führerschein kann teilnehmen. Insgesamt nehmen 30 Personen teil, wobei eine Person ausgeschlossen wurde, weil sie nur an zwei Terminen erschien. Die verbleibende Stichprobe umfasst 29 Probanden, davon 10 weiblich und 19 männlich. Ihr Alter variiert zwischen 18 und 59 Jahren, mit einem Mittelwert von 27,6 Jahren und einer Standardabweichung von 12,3 Jahren. Die Probanden besitzen ihren Führerschein im Durchschnitt seit 9,5 Jahren ( $SD = 12$  Jahre) und fahren durchschnittlich 9310,3 km pro Jahr ( $SD = 7407,1$  km/Jahr). 15 Probanden fahren mehrmals pro Woche oder täglich Auto. Drei Probanden haben bereits an einem Fahrsimulatorversuch teilgenommen und 15 Probanden haben bereits eine VR-Brille benutzt. Sieben Probanden geben an, anfällig für Übelkeit bei Kurvenfahrten zu sein.

### **Datenaufbereitung**

Die Antworten der Probanden werden in der Umfrage-Software LimeSurvey erfasst und können anschließend direkt in Microsoft Excel exportiert werden. Nach dem Export werden die Daten zunächst nach Gruppe, Szene und Proband sortiert. Zur Auswertung wird die Statistik-Software R verwendet. Der detaillierte Prozess der Auswertung für jede abhängige Variable wird in den folgenden Unterkapiteln beschrieben. Aufgrund der unterschiedlichen Verteilung der abhängigen

Variablen werden verschiedene Modelle zur Auswertung verwendet. Zunächst wird die Messung der abhängigen Variablen beschrieben.

## Objektive Daten

**Messung des Situationsbewusstseins:** Um das Situationsbewusstsein zu messen, wird die Situation Awareness Global Assessment Technique (SAGAT) [274] verwendet, die im Gegensatz zu Eyetracking-Methoden [275] auch in Kombination mit einem HMD verwendet werden kann. Diese Methode stoppt die aktuell gezeigte Verkehrssituation und stellt Fragen zu dieser, die auf die drei Ebenen des Situationsbewusstseins ausgerichtet sind. Um die erste Ebene zu erreichen, müssen die Probanden alle relevanten Verkehrsteilnehmer und Schilder richtig erkennen. Für Ebene 2 muss die Position der relevanten Verkehrsteilnehmer richtig wiedergegeben werden, und für Ebene 3 wird die Vorhersage bewertet, wie sich die Verkehrsteilnehmer weiter verhalten werden und ob eine sichere Weiterfahrt möglich ist. Die Fragen zur Erfassung des Situationsbewusstseins lauten dementsprechend: „Welche relevanten Verkehrsteilnehmer und Verkehrsschilder haben Sie gesehen?“ (Ebene 1), „Wo befinden sich die Verkehrsteilnehmer?“ (Ebene 2) und „Wie werden sich die Verkehrsteilnehmer bewegen und ist eine sichere Weiterfahrt möglich?“ (Ebene 3). Um für jeden Probanden pro Szene einen Messwert zu erhalten, werden die Antworten auf die Fragen zum Situationsbewusstsein individuell bewertet.

**Verkehrsteilnehmer:** In jeder Szene sind zwischen null und sieben relevante Verkehrsteilnehmer dargestellt. Die Messwerte werden berechnet, indem die richtig erkannten relevanten Verkehrsteilnehmer und deren Ort durch die Anzahl aller relevanten Verkehrsteilnehmer geteilt wird. Dies entspricht dem prozentualen Anteil der richtig erkannten Verkehrsteilnehmer.

**Verkehrsschilder:** Analog zu den Verkehrsteilnehmern werden die prozentual richtig erkannten Verkehrsschilder gemessen. Hierbei sind minimal null und maximal drei Verkehrsschilder pro Szene vorhanden.

**Geschwindigkeit:** Die Messung der Geschwindigkeitswahrnehmung ist die Differenz zwischen der am Ende der Szene geschätzten Geschwindigkeit und der realen Geschwindigkeit des Fahrzeugs. Szenen, die mit einem Stillstand enden, werden nicht in die Bewertung einbezogen.

**Fahrspur:** Um die Auswirkungen der unabhängigen Variablen auf die Fahrspur zu bestimmen, wurden die Probanden nach jeder Szene nach ihrer Einschätzung der Position des Fahrzeugs auf der Fahrspur gefragt. Die Probanden konnten weit links, links, mittig, rechts und weit rechts antworten. Wird die Position richtig geschätzt, wird die Antwort mit 0 bewertet; zu weit links mit -1 und zu weit rechts mit 1.

**Vorhersage:** Um die Prädiktion des zukünftigen Verkehrsgeschehens beurteilen zu können, wird am Ende jeder Szene gefragt, ob eine sichere Weiterfahrt möglich ist. Die Probanden können diese Frage entweder mit Ja, Nein oder einer plausiblen Begründung beantworten. Eine falsche Antwort wird mit 0, eine richtige mit 1 und bei Unentschlossenheit mit nachvollziehbarer Begründung mit 0,5 gewertet. [263]

## Subjektive Daten

**Abschlussfragebogen:** Zur Erfassung der subjektiven Messdaten füllen die Probanden am Ende jedes Termins den Abschlussfragebogen aus. Der Abschlussfragebogen umfasst Fragen zur Gebrauchstauglichkeit, zum Workload, zur Immersion und zur Presence.

**Usability:** Die Bewertung der Usability erfolgt anhand des AttrakDiff [276], PANAS [277] und des Isonorm 9241/110 [278] Fragebogens. Die Fragen des AttrakDiff-Fragebogens beziehen sich auf fünf Wortpaare, die jeweils einen unterschiedlichen Polarisierungsgrad (angenehm – unangenehm, praktisch – unpraktisch, gut – schlecht, übersichtlich – verwirrend und widerspenstig – handhabbar) aufweisen [276]. Drei weitere Fragen aus dem PANAS-Fragebogen zielen auf die emotionale Befindlichkeit der Probanden ab. Die restlichen Fragen beziehen sich auf Zustimmung- und Ablehnungsskalen aus dem Isonorm-Fragebogen. Einige der Fragen sind nicht auf die Studie anwendbar oder haben keine interpretierbare Bedeutung und werden daher ausgelassen. Insgesamt werden 15 Fragen zur Usability gestellt und anhand einer fünfstufigen Skala mit Nullpunkt gemessen.

**Workload:** Die Arbeitsbelastung wird mit dem NASA-TLX [244] Fragebogen gemessen. Dieser misst die subjektive Arbeitsbelastung bei der Durchführung von Aufgaben. Er umfasst sechs Dimensionen: Mentale Anforderung, physische Anforderung, zeitliche Anforderung, Leistung, Anstrengung und Frustration. Jede Dimension wird auf einer Skala von 0 bis 100 bewertet und kombiniert, um einen Gesamtindex für die Arbeitsbelastung zu erhalten. Laut Hart [279, S. 906] ist der zweite Schritt im NASA TLX optional und seine Auslassung beeinträchtigt die Aussagekraft nicht. Der globale Belastungswert ergibt sich aus dem ungewichteten Durchschnitt der einzelnen Dimensionen.

**Präsenz und Immersion:** Das Empfinden von Präsenz und Immersion wird mit Hilfe des IQP-Fragebogens [211, S. 221] erfasst. Irrelevante Fragen wurden entfernt, sodass insgesamt fünf Fragen für die Messung verwendet werden. Die Fragen werden auf einer siebenstufigen Skala mit Nullpunkt bewertet.

## 6.2 Auswertung Studie 1: Situationsbewusstsein, Anzeigergeräte und Darstellungsformen

Weil die Probanden dieselbe Szene nie in beiden Qualitäten gesehen haben, handelt es sich bei dem Studiendesign um ein gekreuztes oder verschachteltes Messwiederholungsdesign. Dies bedeutet, dass die beiden Messwiederholungsfaktoren (Qualität und Termin) nicht vollständig unabhängig voneinander sind. Solche Designs können beispielsweise mit einer gemischten ANOVA oder mit generalisierten linearen gemischten Modellen (GLMM) modelliert werden, wobei GLMM sowohl lineare gemischte Modelle (LMM) für kontinuierliche Daten als auch logistische Modelle (LOMM) für kategoriale oder binomiale Daten umfasst.

LMM bieten den Vorteil, zufällige Fehler berücksichtigen zu können. Dies ist besonders vorteilhaft, wenn es große Unterschiede zwischen den einzelnen Probanden gibt, weil diese im Modell berücksichtigt werden können. Um die Voraussetzungen zur Verwendung von LMM zu überprüfen wird das DHARMA-Paket [280] verwendet. Dieses erzeugt standardisierte Residuen aus den Vorhersagen eines allgemeinen linearen gemischten Modells (GLMM). Es verwendet Simulationen, um die erwartete Verteilung der Residuen zu berechnen, und ermöglicht so eine genaue und zuverlässige Überprüfung der Modellannahmen. Die Residuen können zur Überprüfung der Gleichverteilung und Homoskedastizität sowie zum Nachweis von Ausreißern oder Einflusspunkten genutzt werden [280].

### 6.2.1 A. Wahrnehmung Verkehrsteilnehmer

An jedem Versuchstag werden den Probanden sieben zufällig ausgewählte Szenen in zufälliger Qualität gezeigt. Jede Szene endet an einem zufälligen Zeitpunkt, und die Probanden werden aufgefordert, die relevanten Verkehrsteilnehmer sowie deren Positionen zu nennen. Die Versuchsleiter vergleichen die Anzahl der korrekt erkannten Verkehrsteilnehmer mit der Anzahl der tatsächlich vorhandenen Verkehrsteilnehmer.

Das LOMM für die abhängige Variable „Verkehrsteilnehmer“ berücksichtigt die Interaktion zwischen HMI und Termin sowie HMI und Qualität. Als zufällige Effekte werden die Probanden und die jeweilige Szene berücksichtigt. Zur Auswertung der Daten werden die erkannten Verkehrsteilnehmer mit den tatsächlich vorhandenen Verkehrsteilnehmern verglichen. Bei der hierbei entstehenden Verteilung handelt es sich um eine binomiale Verteilung, die mit einem LOMM modelliert werden kann. Die Analyse der Residuen des Modells zeigt keine Signifikanz. Die Auswertung mittels eines LOMM ist somit möglich (Anhang A.1).

#### A. Einfluss HMI

Über alle Versuchstage hinweg wurden in der M2D-Gruppe im Durchschnitt am meisten Verkehrsteilnehmer erkannt  $M_{M2D}=78,65\%$ , verglichen mit der M3D-Gruppe  $M_{M3D}=72,61\%$  und der HMD-Gruppe  $M_{HMD}=75,14\%$  (Abbildung 6.3). Das LOMM zeigt einen tendenziellen Effekt der M3D-Gruppe ( $\beta_1=-0,390$ ,  $p=0,053$ ).

Dennoch ist die Nullhypothese  $H_{A,1}$  (Das HMI keinen Einfluss auf die erkannten Verkehrsteilnehmer) anzunehmen.

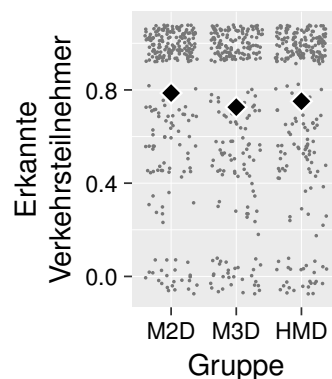


Abbildung 6.3: Jitterplot und Mittelwert der erkannten Verkehrsteilnehmer [%] über die drei Gruppen

#### A.2 Einfluss Qualität

Mit der hohen Qualität des Videostreams haben die Probanden über alle Termine hinweg durchschnittlich  $M_H=77,91\%$  der relevanten Verkehrsteilnehmer erkannt und  $M_N=73,14\%$  mit der niedrigen Qualität. Obwohl mit der hohen Qualität mehr Verkehrsteilnehmer erkannt werden, ist insgesamt kein signifikanter Effekt feststellbar ( $\beta_1=-0,040$ ,  $p=0,752$ ).

Innerhalb der einzelnen Gruppen ist der Effekt der Qualität ebenfalls nicht signifikant. So beträgt der Unterschied in der M2D-Gruppe  $\Delta M_{M2D,H-N}=0,9\%$  ( $\beta_1=0,106$ ,  $p=0,647$ ) und in der M3D-Gruppe  $\Delta M_{M3D,H-N}=3,7\%$  ( $\beta_1=0,219$ ,  $p=0,299$ ). In der HMD-Gruppe ist der Effekt der Qualität am größten  $\Delta M_{HMD,H-N}=9,64\%$  und statistisch tendenziell signifikant ( $\beta_1=-0,415$ ,  $p=0,055$ ). Mit dem HMD und der hohen Qualität konnten die meisten Verkehrsteilnehmer erkannt werden  $M_{HMD,H}=79,94\%$  (Abbildung 6.4).

Dennoch ist die Nullhypothese  $H_{A,2}$  (Die Qualität hat keinen Einfluss auf die erkannten Verkehrsteilnehmer) anzunehmen.

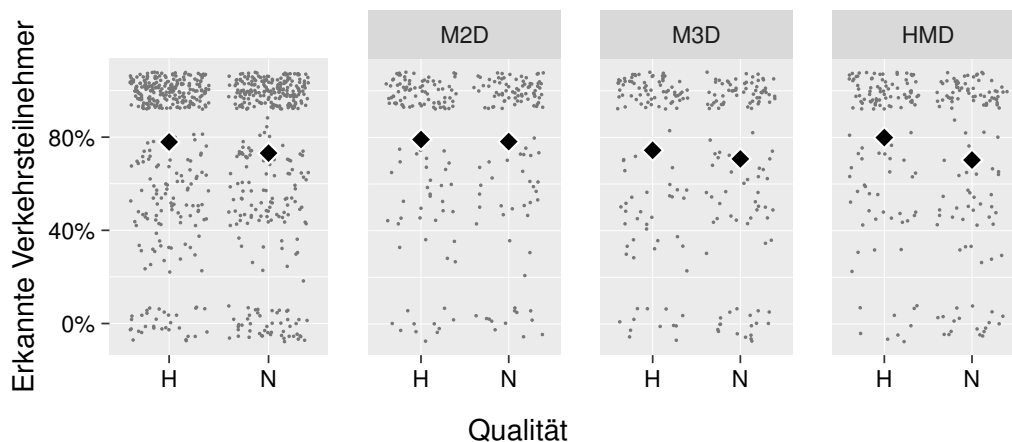


Abbildung 6.4: Jitterplot und Mittelwert der erkannten Verkehrsteilnehmer [%] über die Qualität hoch und niedrig

### A.3 Einfluss Termin

Deskriptiv wurden über alle Gruppen hinweg an Termin 1  $M_{T1}=71,24\%$ , an Termin 2  $M_{T2}=76,27\%$ , an Termin 3  $M_{T3}=81,37\%$  und an Termin 4  $M_{T4}=73,39\%$  der Verkehrsteilnehmer erkannt. An Termin 3 wurden die meisten Verkehrsteilnehmer erkannt. Der Effekt des Termins 3 ist **signifikant** ( $\beta_1=0,404$ ,  $p=0,026$ ). Innerhalb der M2D-Gruppe ist der Termin 4 nicht signifikant ( $\beta_1=-0,564$ ,  $p=0,064$ ); die Termine in den anderen Gruppen zeigen keinen signifikanten Effekt. Die meisten Verkehrsteilnehmer wurden in der M2D-Gruppe an Termin 3  $M_{M2D,T3}=84,26\%$  erkannt, und die wenigsten in der M3D-Gruppe an Termin 1  $M_{M3D,T1}=66,52\%$  (Abbildung 6.5).

Die Nullhypothese  $H_{A,3}$  (Die Nutzungshäufigkeit des HMI hat keinen Einfluss auf die erkannten Verkehrsteilnehmer) wird abgelehnt.

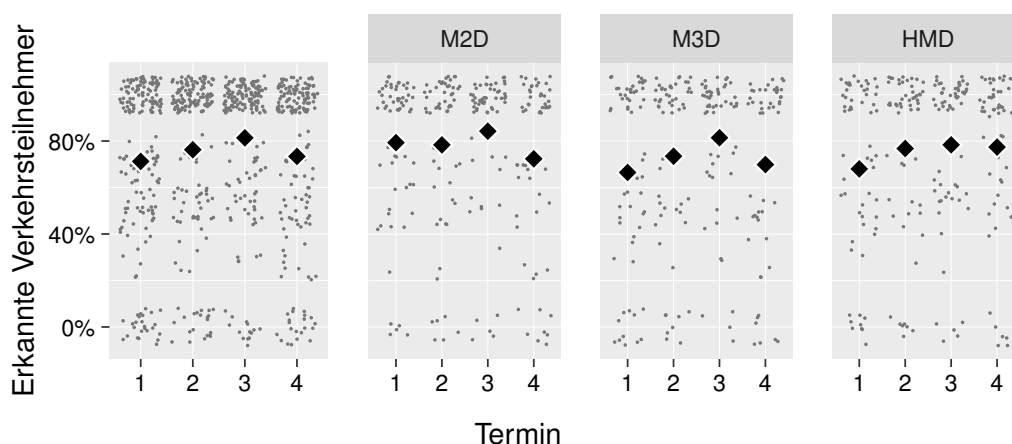


Abbildung 6.5: Mittelwert und Perzentile der erkannten Verkehrsteilnehmer [%] über die vier Termine

## 6.2.2 B. Wahrnehmung Verkehrsschilder

Zusätzlich zu den erkannten Verkehrsteilnehmern werden die Probanden aufgefordert, relevante Verkehrsschilder zu nennen. In 13 der 24 Szenen kommen Verkehrsschilder vor, wobei maximal zwei Schilder pro Szene zu sehen sind. Aufgrund der binomialen Verteilung der Daten wird ebenfalls ein LOMM verwendet. Die Interaktion zwischen Gruppe und Qualität sowie zwischen Gruppe und Termin hat keine signifikanten Effekte aufgezeigt. Daher wird ein vereinfachtes Modell verwendet, das keine Interaktion zwischen den unabhängigen Variablen berücksichtigt. Sowohl die Szene als auch die Probanden werden als zufällige Fehler modelliert. Die Residualanalyse zeigt, dass die Annahmen zur Verwendung des Modells erfüllt sind (Anhang A.2).

### B.1 Einfluss HMI

Deskriptiv wurden über alle Versuchstage hinweg in der M2D-Gruppe am meisten Verkehrsschilder erkannt  $M_{M2D}=76,04\%$ , gefolgt von der HMD-Gruppe  $M_{HMD}=73,85\%$  und der M3D-Gruppe  $M_{M3D}=69,96\%$  (Abbildung 6.6). Der Effekt der Darstellungsform M3D ist nicht signifikant ( $\beta_1=-0,381$ ,  $p=0,186$ ), ebenso der Effekt der HMD-Gruppe ( $\beta_1=-0,002$ ,  $p=0,993$ ).

Die Nullhypothese  $H_{B.1}$  (Das HMI hat keinen Einfluss auf die erkannten Verkehrsschilder) wird angenommen.




Abbildung 6.6: Jitterplot und Mittelwert der erkannten Verkehrsschilder [%] über die drei Gruppen

### B.2 Einfluss Qualität

Über alle Gruppen und Versuchstage hinweg wurden mit der hohen Qualität im Mittel  $M_H=74,22\%$  und mit der niedrigen Qualität  $M_N=72,46\%$  aller Verkehrsschilder erkannt. Der Effekt der Qualität ist insgesamt nicht signifikant ( $\beta_1=-0,271$ ,  $p=0,218$ ) (Abbildung 6.7). In den einzelnen Gruppen wurden in der M2D-Gruppe mit der hohen Qualität die meisten Verkehrsschilder  $M_{M2D,H}=78,75\%$  und in der M3D-Gruppe mit der niedrigen Qualität die wenigsten  $M_{M3D,H}=69,91\%$  erkannt. Insgesamt hat die Qualität nur Auswirkungen auf die erkannten Verkehrsschilder in der M2D-Gruppe. Der Effekt der Qualität ist in allen drei Gruppen nicht signifikant, M2D ( $\beta_1=-0,463$ ,  $p=0,230$ ), M3D ( $\beta_1=-0,012$ ,  $p=0,976$ ) und HMD ( $\beta_1=-0,279$ ,  $p=0,449$ ).

Die Nullhypothese  $H_{B.2}$  (Die Qualität hat keinen Einfluss auf die erkannten Verkehrsschilder) wird angenommen.

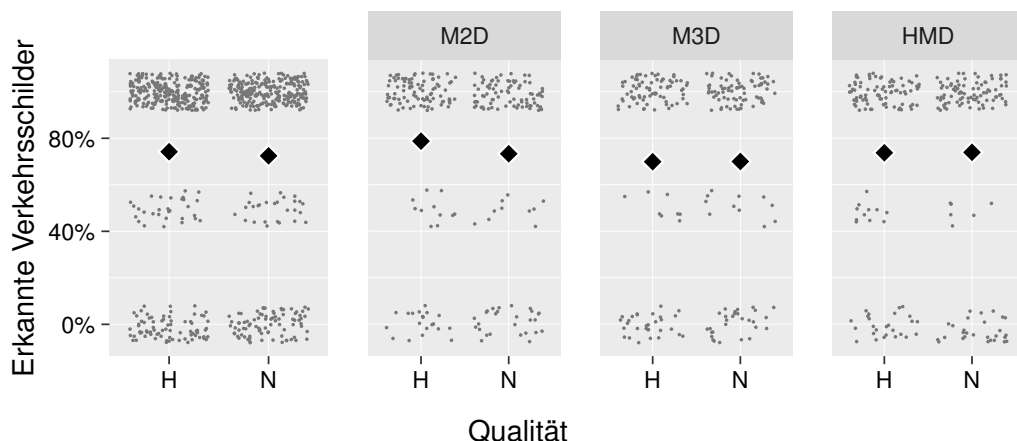


Abbildung 6.7: Jitterplot und Mittelwert der erkannten Verkehrsschilder [%] über die drei Gruppen und die Qualität

### B.3 Einfluss Termin

Über alle Gruppen wurden am vierten Versuchstag die meisten Verkehrsschilder erkannt  $M_{T4}=78,24\%$ , an allen anderen Tagen weniger. Dabei wurden am dritten Versuchstag die wenigsten Schilder erkannt  $M_{T3}=68,93\%$ . Der Effekt des Termins 4 ist über alle Gruppen hinweg **signifikant** ( $\beta_1=0,649$ ,  $p=0,031$ ). Innerhalb der einzelnen Gruppen wurde die höchste Erkennungsrate in der M2D-Gruppe an Termin 2 erreicht  $M_{M2D,T2}=81,03\%$ , gefolgt von Termin 4 in der HMD-Gruppe  $M_{HMD,T4}=80,51\%$ . Die wenigsten Schilder wurden in der M3D-Gruppe an Tag 3 erkannt  $M_{M3D,T3}=60,00\%$ . Sowohl in der M2D- als auch in der M3D-Gruppe gibt es keine signifikanten Effekte des Termins. In der HMD-Gruppe ist der Effekt des Termins 4 nicht signifikant ( $\beta_1=0,819$ ,  $p=0,093$ ). Deskriptiv ist in der HMD-Gruppe über die vier Termine ein Aufwärtstrend erkennbar.

Die Nullhypothese  $H_{B.3}$  (Die Nutzungshäufigkeit des HMI hat keinen Einfluss auf die erkannten Verkehrsschilder) wird abgelehnt.

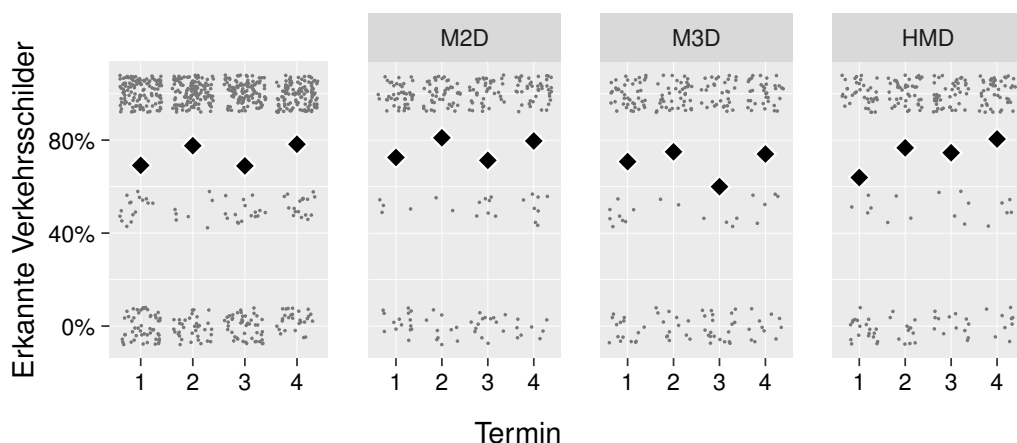


Abbildung 6.8: Jitterplot und Mittelwert der erkannten Verkehrsschilder [%] über die drei Gruppen und Termine

#### 6.2.3 C. Schätzung der Geschwindigkeit

Als weiterer unabhängiger Faktor werden die Probanden nach jeder Szene gebeten, die gegenwärtige Geschwindigkeit des Fahrzeugs zu schätzen. Für die Analyse wird die Differenz



zwischen der geschätzten und der tatsächlich gefahrenen Geschwindigkeit verwendet. Hierbei werden ausschließlich Szenen in Betracht gezogen, die nicht mit einem Stillstand des Fahrzeugs enden.

Die Datenauswertung zeigt eine logarithmische Normalverteilung (Anhang A.3), die mit einem LMM modelliert werden kann. Für die Anwendung des LMM werden die Daten zwischen 0 und 1 normiert. Das Modell berücksichtigt Gruppe, Qualität und Termin als unabhängige Variablen sowie Probanden und Szenen als zufällige Fehler. Zusätzlich wird die Interaktion zwischen Gruppe und Termin sowie zwischen Gruppe und Qualität berücksichtigt.

Die Analyse der Residuen mithilfe des DHARMA-Pakets [280] zeigt, dass die Voraussetzungen für die Verwendung eines LMM erfüllt sind (Anhang A.3). In den nachfolgenden Kapiteln werden die Einflüsse der jeweiligen unabhängigen Variablen auf die Geschwindigkeit dargestellt.

## C.1 Einfluss HMI

Über alle Versuchstage hinweg wurde die Geschwindigkeit in allen Gruppen im Durchschnitt zu hoch eingeschätzt. So liegt der durchschnittliche Fehler in der M2D-Gruppe bei  $M_{M2D}=3,41$  km/h, in der M3D-Gruppe bei  $M_{M3D}=4,22$  km/h und in der HMD-Gruppe bei  $M_{HMD}=4,23$  km/h. Generell wird während der Teleoperation die Geschwindigkeit zu hoch eingeschätzt, was auch an den Ausreißern in den Boxplots zu erkennen ist (Abbildung 6.9). Die Auswertung des LMM zeigt keinen signifikanten Effekt der M3D-Gruppe ( $\beta_1=0,013$ ,  $p=0,603$ ) oder der HMD-Gruppe ( $\beta_1=0,017$ ,  $p=0,484$ ).

Die Nullhypothese  $H_{C,1}$  (Das HMI hat keinen Einfluss auf die geschätzte Geschwindigkeit) wird angenommen.




Abbildung 6.9: Boxplot des Fehlers der Geschwindigkeitsschätzung über die drei Gruppen

## C.2 Einfluss Qualität

Auch in Abhängigkeit der Qualität existieren nur geringe Unterschiede in der Schätzung der Geschwindigkeit. So lag der Fehler bei der durchschnittlich geschätzten Geschwindigkeit über alle Versuchstage hinweg bei der hohen Qualität bei  $M_H=5,59$  km/h und bei der niedrigen Qualität  $M_N=4,94$  km/h. Auch innerhalb der Gruppen ist die Fehleinschätzung vergleichbar (Abbildung 6.10). Die Auswertung des LMM zeigt insgesamt keinen signifikanten Effekt der Qualität ( $\beta_1=0,011$ ,  $p=0,281$ ). Auch innerhalb der Gruppen gibt es keine signifikanten Effekte der Qualität auf die Geschwindigkeitsschätzung, M2D ( $\beta_1=-0,026$ ,  $p=0,117$ ), M3D ( $\beta_1=0,019$ ,  $p=0,332$ ) und HMD ( $\beta_1=-0,022$ ,  $p=0,237$ ). Einzig die Interaktion der Gruppe M3D und der Qualität N zeigt einen tendenziellen Effekt ( $\beta_1=0,045$ ,  $p=0,082$ ).

Die Nullhypothese  $H_{C,2}$  (Die Qualität hat keinen Einfluss auf die geschätzte Geschwindigkeit) wird angenommen.




Abbildung 6.10: Boxplot des Fehlers der Geschwindigkeitsschätzung über die drei Gruppen und der Qualität

### C.3 Einfluss Termin

Deskriptiv liegt der durchschnittliche Fehler der Geschwindigkeitsschätzung über alle Gruppen, an Termin 1 bei  $M_{T1}=6,59$  km/h, an Termin 2 bei  $M_{T2}=4,42$  km/h, an Termin 3 bei  $M_{T3}=5,74$  km/h und an Termin 4 bei  $M_{T4}=4,12$  km/h. Obwohl ein Abwärtstrend des Fehlers über die einzelnen Termine vorliegt, ist der Effekt der unabhängigen Variable Termin insgesamt nicht signifikant, Termin 2 ( $\beta_1=-0,009$ ,  $p=0,583$ ), Termin 3 ( $\beta_1=-0,000$ ,  $p=0,992$ ) und Termin 4 ( $\beta_1=-0,022$ ,  $p=0,172$ ). Die Betrachtung der einzelnen Gruppen zeigt keine signifikanten Effekte des Faktors Termin in der Gruppe M2D und HMD. In der Gruppe M3D ist der Effekt des Termins 4 **signifikant** ( $\beta_1=-0,100$ ,  $p=0,001$ )  $M_{M3D,T4}=2,5$  km/h verglichen mit dem ersten Termin 1  $M_{M3D,T1}=8,42$  km/h. Beide Termine markieren über alle Gruppen hinweg den größten und kleinsten Fehler in der Geschwindigkeitsschätzung.

Die Nullhypothese  $H_{C,3}$  (Die Nutzungshäufigkeit des HMI hat keinen Einfluss auf die geschätzte Geschwindigkeit) wird abgelehnt.




Abbildung 6.11: Boxplot des Fehlers der Geschwindigkeitsschätzung über die vier Termine und drei Darstellungsformen

## 6.2.4 D. Schätzung der Spur

Im Rahmen der Situationsbewusstseins Messung beurteilen die Probanden auch ihre räumliche Wahrnehmung hinsichtlich der Position des Fahrzeugs auf der Fahrbahn. Nach jeder Szene werden sie gebeten, die aktuelle Position des Fahrzeugs in Relation zur Fahrbahnmitte zu schätzen, wobei die Auswahlmöglichkeiten mittig, links oder rechts umfassen. Die Versuchsleiter vermerken, ob die jeweilige Schätzung korrekt oder inkorrekt ist.

Die resultierende Datenverteilung folgt einer Bernoulli-Verteilung, einer speziellen Form der Binomialverteilung, und kann durch ein LOMM analysiert werden. Das verwendete Modell berücksichtigt die Effekte der Gruppe, Darstellungsform, Qualität, Termin sowie zufällige Effekte wie Proband und Szene. Darüber hinaus werden die Interaktionen zwischen Gruppe und Termin sowie zwischen Gruppe und Qualität berücksichtigt.

Die durchgeführte Residualanalyse bestätigt die Erfüllung der Voraussetzungen für die Anwendung des LOMM (Anhang A.4). In den folgenden Abschnitten werden die Einflüsse der verschiedenen unabhängigen Variablen auf die Schätzung der Position in Bezug zur Fahrbahnmitte diskutiert.

### D.1. Einfluss HMI

Über alle Versuchstage wurde die Spur in der M2D-Gruppe mit  $M_{M2D}=56,25\%$  am häufigsten richtig eingeschätzt. Sowohl die M3D-Gruppe als auch die HMD-Gruppe haben ein vergleichbares Ergebnis erzielt, mit  $M_{M3D}=51,75\%$  und  $M_{HMD}=52,3\%$ . Insgesamt gibt es über alle Termine keinen signifikanten Effekt der Gruppe M3D ( $\beta_1=-0,186$ ,  $p=0,537$ ) oder der Gruppe HMD ( $\beta_1=-0,211$ ,  $p=0,478$ ).

Die Nullhypothese  $H_{D,1}$  (Das HMI hat keinen Einfluss auf die Schätzung der Spur) wird angenommen.




Abbildung 6.12: Anteil richtiger Antworten in der Schätzung der Fahrspur über die Darstellungsform

### D.2 Einfluss Qualität

Die Qualität zeigt über alle Gruppen und Termine einen tendenziellen Effekt auf die Schätzung der Spur ( $\beta_1=-0,301$ ,  $p=0,082$ ). Im Durchschnitt wurden mit der hohen Qualität in 56,09% und mit der niedrigen Qualität in 50,85% der Szenen die Position des Fahrzeugs richtig eingeschätzt.

Innerhalb der Gruppen hat die Qualität in der M3D-Gruppe einen **signifikanten** Effekt ( $\beta_1=-0,743$ ,  $p=0,025$ ) und keinen Effekt in der M2D- ( $\beta_1=-0,224$ ,  $p=0,459$ ) oder HMD-Gruppe ( $\beta_1=-0,062$ ,  $p=0,828$ ). Am häufigsten wurde die Spur in der M3D-Gruppe richtig eingeschätzt, mit der

hohen Qualität  $M_{M3D,H}=57,5\%$  und am seltensten in der M3D-Gruppe mit der niedrigen Qualität  $M_{M3D,L}=46,1\%$ .

Die Nullhypothese  $H_{D,2}$  (Die Qualität hat einen Einfluss auf die Schätzung der Spur) wird für die M3D-Gruppe abgelehnt.




Abbildung 6.13: Anteil richtiger Antworten in der Schätzung der Fahrspur über die Qualität

### D.3 Einfluss Termin

Der Faktor Termine zeigt über alle Gruppen und Qualitäten keinen Effekt auf die Erkennung der Spur. So wurden am ersten Tag 55,32%, am zweiten 51,74% ( $\beta_1=-0,407$ ,  $p=0,109$ ), am dritten 55,93% ( $\beta_1=-0,022$ ,  $p=0,930$ ) und am vierten 50,59% ( $\beta_1=-0,337$ ,  $p=0,176$ ) der Szenen richtig eingeschätzt.

Bei Betrachtung der einzelnen Gruppen hat der Termin 2 der M2D-Gruppe einen signifikanten Effekt ( $\beta_1=-1,128$ ,  $p=0,013$ ) sowie der Termin 4 in der M3D-Gruppe ( $\beta_1=-1,091$ ,  $p=0,023$ ). In der HMD-Gruppe gibt es keinen signifikanten Effekt des Faktors Termin. Die beste Leistung wurde in der M2D-Gruppe am vierten Tag erzielt, mit 62,71%, und die schlechteste Leistung an Tag vier in der M3D-Gruppe mit 38,46%.

Die Nullhypothese  $H_{D,3}$  (Die Nutzungshäufigkeit des HMI hat einen Einfluss auf die Schätzung der Spur) wird abgelehnt.




Abbildung 6.14: Anteil richtiger Antworten in der Schätzung der Fahrspur über die Termine

## 6.2.5 E. Vorhersage

Als letzte Stufe der Situation Awareness wird die Vorhersage der Situation abgefragt. Die Probanden sollen am Ende jeder Szene einschätzen, ob eine sichere Weiterfahrt möglich ist, oder ob eine Gefahr droht. Die Versuchsleiter vermerken, ob die jeweilige Antwort richtig oder falsch ist.

Die sich ergebende Verteilung ist ebenfalls eine Bernoulli-Verteilung (Kapitel 6.2.4). Das verwendete Modell berücksichtigt die Effekte der Gruppe, Darstellungsform, Qualität, Termin sowie die zufälligen Effekte Proband und Szene. Darüber hinaus wurden die Interaktionen zwischen Gruppe und Termin betrachtet; sie ergaben keine signifikanten Effekte, es wird daher ein vereinfachtes Modell ohne Interaktion verwendet.

Die Residualanalyse zeigt, dass die Voraussetzungen für die Verwendung eines LOMM erfüllt sind (Anhang A.5.1). Die folgenden Abschnitte beschreiben die Effekte der unabhängigen Variablen auf die Vorhersage der sicheren Weiterfahrt.

### E.1 Einfluss HMI

Über alle Versuchstage und Qualitäten wurden deskriptiv in der M2D-Gruppe mit 67,76% die meisten Szenen richtig vorhergesagt, gefolgt von den Probanden in der M3D-Gruppe mit 62,94% und den Probanden in der HMD-Gruppe mit 59,62%.

Das LOMM zeigt, dass der Effekt der Gruppe sowohl für die M2D-Gruppe ( $\beta_1 = -0,265$ ,  $p = 0,334$ ) als auch für die HMD-Gruppe nicht signifikant ( $\beta_1 = -0,440$ ,  $p = 0,104$ ) ist.

Die Nullhypothese  $H_{E,1}$  (Das HMI hat keinen Einfluss auf die Vorhersage der sicheren Weiterfahrt) wird angenommen.




Abbildung 6.15: Anteil richtiger Antworten in der Vorhersage über die Gruppe

### E.2 Einfluss Qualität

Im Durchschnitt wurden mit der hohen Qualität 67% und mit der niedrigen 59,89% der Szenen richtig vorhergesagt. Das LOMM zeigt über alle Gruppen und Termine einen **signifikanten** Effekt der Qualität ( $\beta_1 = -0,371$ ,  $p = 0,031$ ) auf die Vorhersage der sicheren Weiterfahrt.

Innerhalb der einzelnen Gruppen wurde deskriptiv die beste Vorhersagegenauigkeit von 69,58% in der M2D-Gruppe mit der hohen Qualität erzielt, und die schlechteste Vorhersagegenauigkeit von 54,62% in der HMD-Gruppe mit der niedrigen Qualität. Im Gegensatz zur M2D- ( $\beta_1 = -0,216$ ,  $p = 0,489$ ) und M3D- ( $\beta_1 = -0,406$ ,  $p = 0,184$ ) Gruppe, hat die Qualität in der HMD-Gruppe einen tendenziellen Effekt auf die Vorhersagegenauigkeit ( $\beta_1 = -0,484$ ,  $p = 0,089$ ).

Die Nullhypothese  $H_{E.2}$  (Die Qualität hat einen Einfluss auf die Vorhersage der sicheren Weiterfahrt) wird abgelehnt.




Abbildung 6.16: Anteil richtiger Antworten in der Vorhersage über die Qualität

### E.3 Einfluss Termin

Obwohl insgesamt deskriptiv ein Anstieg der Vorhersagegenauigkeit über die einzelnen Termine zu erkennen ist, zeigt das LOMM keinen signifikanten Effekt des Faktors Termin zwei ( $\beta_1=-0,167$ ,  $p=0,506$ ), drei ( $\beta_1=-0,028$ ,  $p=0,908$ ) oder vier ( $\beta_1=0,191$ ,  $p=0,443$ ). Wobei am ersten Termin mit 60,37% die Vorhersagegenauigkeit am geringsten und am vierten Termin mit 68,53% am höchsten war.

Auch innerhalb der M2D- und M3D-Gruppe gibt es keinen signifikanten Effekt des Faktors Termin auf die Vorhersagegenauigkeit. Einziger Termin vier in der HMD-Gruppe zeigt einen tendenziellen Effekt ( $\beta_1=0,735$ ,  $p=0,078$ ).

Die Nullhypothese  $H_{E.3}$  (Die Nutzungshäufigkeit des HMI hat keinen Einfluss auf die Vorhersage der sicheren Weiterfahrt) wird angenommen.



Abbildung 6.17: Anteil richtiger Antworten in der Vorhersage über die Termine

## 6.2.6 F. Usability

Die Usability wird im ersten Abschnitt des Abschlussfragebogens beurteilt und umfasst Fragen aus dem AttrakDiff- [276] PANAS [277] und Isonorm 9241/110 Fragebogen [278]. Die Probanden haben die Möglichkeit, die jeweiligen Fragen auf einer Skala von -2 bis 2 zu bewerten. Ein höherer Gesamtwert entspricht einer positiveren Bewertung. Durch Zusammenfassung der Einzelantworten wird ein Indikatorwert für die Gebrauchstauglichkeit des HMI ermittelt.

Das LMM für die abhängige Variable Usability berücksichtigt die Interaktion zwischen HMI und Testtermin sowie zwischen HMI und Qualität. Als zufällige Variable wird die Variation zwischen den Probanden berücksichtigt. Die Residualanalyse (Anhang A.6) bestätigt die Annahme einer Normalverteilung, wodurch ein LMM für die Datenanalyse verwendet werden kann.

### F.1 Einfluss HMI

In der Gesamtbetrachtung aller Versuchstage erreichte die M2D-Version des HMI die höchste Bewertung ( $M_{M2D}=0,88$ ). Es folgen die HMD-Gruppe mit einer Bewertung von  $M_{HMD}=0,79$  und die M3D-Gruppe mit  $M_{M3D}=0,58$ .

Die Auswertung des LMM ergab einen tendenziellen Effekt für die M3D-Gruppe ( $\beta_1=-0,467$ ,  $p=0,097$ ), während kein signifikanter Einfluss der HMD-Gruppe festgestellt wurde ( $\beta_1=-0,173$ ,  $p=0,530$ ).

Daher wird die Nullhypothese  $H_{F,1}$  (Das HMI hat keinen Einfluss auf die Usability) abgelehnt.




Abbildung 6.18: Usability über die drei Gruppen

### F.2 Einfluss Qualität

Über alle Versuchstage hinweg haben sowohl die niedrige als auch die hohe Qualität zu der gleichen Usability-Bewertung geführt. Beide Qualitäten haben einen Mittelwert von  $M_{N,H}=0,75$  erzielt. Die Analyse der einzelnen Gruppen zeigt keine Korrelationseffekte zwischen Gruppe und Qualität. So wurde in der M2D-Gruppe mit der niedrigen Qualität ein Mittelwert von  $M_{M2D,N}=0,89$  und mit der hohen Qualität  $M_{M2D,H}=0,86$  erzielt, ohne signifikanten Effekt ( $\beta_1=-0,002$ ,  $p=0,984$ ). Ähnliche Ergebnisse sind in der M3D-Gruppe  $M_{M3D,N}=0,59$ ,  $M_{M3D,H}=0,56$ , ( $\beta_1=0,000$ ,  $p=0,880$ ) und in der HMD-Gruppe  $M_{HMD,N}=0,76$  und  $M_{HMD,H}=0,82$  mit ( $\beta_1=-0,1$ ,  $p=0,430$ ) zu finden.

Die Nullhypothese  $H_{F,2}$  (Die Qualität hat keinen Einfluss auf die Usability) ist anzunehmen.




Abbildung 6.19: Usability über Qualität

### F.3 Einfluss Termin

Über alle Gruppen hinweg zeigt der Faktor Termin einen signifikanten Effekt auf die Usability-Bewertung der Probanden. Die Mittelwerte für die einzelnen Termine sind  $M_{T1}=0,58$ ,  $M_{T2}=0,76$ ,  $M_{T3}=0,82$  und  $M_{T4}=0,85$ , mit den jeweils **signifikanten** Effekten: Termin 2 ( $\beta_1=0,202$ ,  $p=0,016$ ), Termin 3 ( $\beta_1=0,252$ ,  $p=0,003$ ) (stark) und Termin 4 ( $\beta_1=0,287$ ,  $p=0,001$ ) (sehr stark).




Abbildung 6.20: Usability über die Termine

Die Analyse der einzelnen Gruppen zeigt, dass der Faktor Termin in der M2D-Gruppe keinen signifikanten Effekt hat; Termin 2 ( $\beta_1=0,075$ ,  $p=0,620$ ), Termin 3 ( $\beta_1=0,194$ ,  $p=0,156$ ), Termin 4 ( $\beta_1=0,048$ ,  $p=0,740$ ). Der größte Effekt der Nutzungsdauer ist in der M3D-Gruppe zu finden. Hier wurde die Usability mit jedem Termin besser bewertet. So hat Termin 2 einen tendenziellen Effekt ( $\beta_1=0,241$ ,  $p=0,060$ ), Termin 3 einen **signifikanten** ( $\beta_1=0,334$ ,  $p=0,015$ ) und Termin 4 einen stark **signifikanten** ( $\beta_1=0,423$ ,  $p=0,003$ ) Effekt. In der HMD-Gruppe ist ein **signifikanter** Effekt nur an Termin 4 festzustellen ( $\beta_1=0,373$ ,  $p=0,042$ ). Termin 2 ( $\beta_1=0,267$ ,  $p=0,139$ ) und 3 ( $\beta_1=0,207$ ,  $p=0,243$ ) haben keinen signifikanten Effekt.

Die Nullhypothese  $H_{F,3}$  (Die Nutzungshäufigkeit des HMI hat keinen Einfluss auf die Usability) ist abzulehnen.



## 6.2.7 G. Workload

Der Workload wird im mittleren Teil des Fragebogens erfasst. Als Grundlage dient der NASA-TLX-Fragebogen. Die Probanden können die Höhe der Anforderung auf einer Skala von 0% (gering) bis 100% (hoch) bewerten. Ein niedrigerer Gesamtwert zeigt eine bessere Bewertung an. Die zusammengefassten Ergebnisse der Einzelfragen ergeben einen Indikatorwert für den Workload der Probanden.

Das LMM für die abhängige Variable Workload berücksichtigt die Interaktion zwischen HMI und Termin sowie zwischen HMI und Qualität. Als zufälliger Effekt wird die Variation zwischen den Probanden gewählt. Die Residualanalyse (Anhang A.7) bestätigt die Annahme der Normalverteilung; die Verwendung eines LMM ist somit möglich.

### G.1 Einfluss HMI

Über alle Versuchstage verteilt haben alle HMI-Varianten eine ähnliche Bewertung des Workloads erhalten. Die M2D-Gruppe hat im Mittel einen Workload von  $M_{M2D}=70,45\%$ , die M3D-Gruppe  $M_{M3D}=71,4\%$  und die HMD-Gruppe  $M_{HMD}=70,96\%$ . Die Analyse des LMM zeigte keine signifikanten Unterschiede zwischen den Gruppen; M3D ( $\beta_1=0,461$ ,  $p=0,873$ ) und HMD ( $\beta_1=0,952$ ,  $p=0,740$ ).

Die Nullhypothese  $H_{G.1}$  (Das HMI hat keinen Einfluss auf den Workload) ist anzunehmen.




Abbildung 6.21: Workload über die drei Gruppen

### G.2 Einfluss Qualität

Insgesamt haben sowohl die niedrige als auch die hohe Qualität zu einem ähnlichen Workload geführt. Die niedrige Qualität hat im Mittel zu einem Workload von  $M_N=70,92\%$  geführt, die hohe Qualität zu einem Workload von  $M_H=70,94\%$ . Über alle Gruppen hat die Qualität keinen signifikanten Effekt auf den Workload ( $\beta_1=0,641$ ,  $p=0,316$ ). Die Analyse der einzelnen Gruppen zeigt einen tendenziellen Effekt der Qualität N auf den Workload in der M2D-Gruppe ( $\beta_1=2,362$ ,  $p=0,077$ ) und keine signifikanten Effekte in der M3D-Gruppe ( $\beta_1=-0,420$ ,  $p=0,668$ ) oder HMD-Gruppe ( $\beta_1=0,198$ ,  $p=0,864$ ).

Die Nullhypothese  $H_{G.2}$  (Die Qualität hat keinen Einfluss auf den Workload) ist anzunehmen.




Abbildung 6.22: Workload über Qualität

### G.3 Einfluss Termin

Über alle Gruppen hinweg zeigt der Faktor Termin einen signifikanten Effekt auf den Workload. Die Mittelwerte der Termine sind  $M_{T_1}=73,17\%$ ,  $M_{T_2}=71,23\%$ ,  $M_{T_3}=70,07\%$  und  $M_{T_4}=69,17\%$  mit den jeweils **signifikanten** Effekten Termin 2 ( $\beta_1=-3,318$ ,  $p=0,067$ ) (schwach), Termin 3 ( $\beta_1=-4,633$ ,  $p=0,005$ ) (sehr stark) und Termin 4 ( $\beta_1=-3,558$ ,  $p=0,041$ ) (stark). Die Nullhypothese  $H_{G.3}$  ist abzulehnen: Der Termin hat einen Einfluss auf den Workload.

Die Analyse der einzelnen Gruppen zeigt, dass der Faktor Termin in der M3D-Gruppe an Tag 4 den stärksten signifikanten Effekt hat ( $\beta_1=-7,454$ ,  $p=1.35e-5$ ) und schwächere Effekte an Tag 2 ( $\beta_1=-3,375$ ,  $p=0,018$ ) und Tag 3 ( $\beta_1=-4,412$ ,  $p=0,004$ ). In der M2D-Gruppe hat Tag 3 den stärksten Effekt mit ( $\beta_1=-4,633$ ,  $p=0,006$ ), gefolgt von Tag 4 ( $\beta_1=-3,558$ ,  $p=0,044$ ) und Tag 2 ( $\beta_1=-3,318$ ,  $p=0,070$ ).

In der HMD-Gruppe gibt es einen tendenziellen Effekt an Tag 4 ( $\beta_1=-2,897$ ,  $p=0,082$ ). In der HMD-Gruppe hatten über alle Termine hinweg die Probanden einen ähnlichen Workload.

Die Nullhypothese  $H_{G.3}$  (Der Termin hat keinen Einfluss auf den Workload) ist abzulehnen.




Abbildung 6.23: Workload über die einzelnen Termine und Gruppen

## 6.2.8 H. Immersion

Die letzten fünf Fragen des Abschlussfragebogens konzentrieren sich auf die Immersion und Präsenz der Probanden. Die Skala ist 7-stufig und verfügt über einen Nullpunkt, sodass die jeweils beste Bewertung mit der Zahl 3 und die schlechteste Bewertung mit der Zahl -3 kodiert ist. Durch die Zusammenfassung der Ergebnisse aus diesen fünf Einzelfragen entsteht ein Indikator für die Immersion und Präsenz der Probanden.

Das aufgestellte LLM berücksichtigt die Interaktionen zwischen HMI und Termin sowie HMI und Qualität. Als zufälliger Effekt wird die Variation zwischen den Probanden berücksichtigt. Die Residualanalyse bestätigt die Annahme der Normalverteilung. Die Verwendung eines LMM ist daher gerechtfertigt (Anhang A.8).

### H.1 Einfluss HMI

Über die HMI verteilt liegt der Mittelwert  $M_g=0,34$ , mit jeweils  $M_{M2D}=0,24$ ,  $M_{M3D}=0,26$  und  $M_{HMD}=0,52$ . Die Immersion ist bei der HMD-Gruppe am höchsten und bei der M2D-Gruppe am geringsten. Das LLM liefert keine signifikanten Unterschiede für die HMD ( $\beta_1=0,346$ ,  $p=0,476$ ) und M2D-Gruppe ( $\beta_1=0,295$ ,  $p=0,543$ ). Die Nullhypothese  $H_{H,1}$  (Das HMI hat keinen Einfluss auf die Immersion) ist anzunehmen.

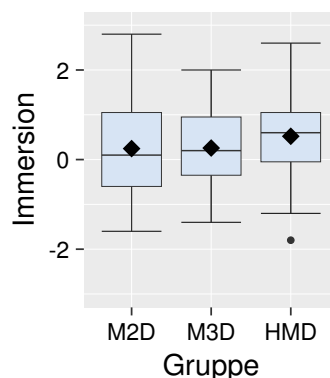


Abbildung 6.24: Immersion über die drei Gruppen

### H.2 Einfluss Qualität

Die Immersion ist bei der Qualität H  $M_H=0,41$  am höchsten und bei der Qualität N  $M_N=0,28$  am geringsten. Das LLM liefert keine signifikanten Unterschiede für die Qualität ( $\beta_1=-0,144$ ,  $p=0,208$ ). Die Nullhypothese  $H_{H,2}$  ist anzunehmen: Die Qualität hat keinen Einfluss auf die Immersion und Präsenz.

Innerhalb der Gruppe M2D hat die Qualität einen **signifikanten** Effekt auf die Immersion und Präsenz ( $\beta_1=-0,3903$ ,  $p=0,0404$ ). In der Gruppe M3D ( $\beta_1=-0,008$ ,  $p=0,642$ ) sowie in der Gruppe HMD ( $\beta_1=-0,086$ ,  $p=0,730$ ) konnte kein signifikanter Effekt der Qualität festgestellt werden.




Abbildung 6.25: Immersion über Qualität

### H.3 Einfluss Termin

Der Mittelwert der Immersion, über die Termine verteilt, liegt bei  $M_{T1}=0,31$ ,  $M_{T2}=0,33$ ,  $M_{T3}=0,4$  und  $M_{T4}=0,33$ . Es existieren keine signifikanten Unterschiede für den Termin 2 ( $\beta_1=0,069$ ,  $p=0,658$ ), Termin 3 ( $\beta_1=0,133$ ,  $p=0,398$ ) und Termin 4 ( $\beta_1=0,084$ ,  $p=0,600$ ). Die Nullhypothese  $H_{H.3}$  (Die Nutzungshäufigkeit des HMI hat keinen Einfluss auf die Immersion und Präsenz) ist anzunehmen.

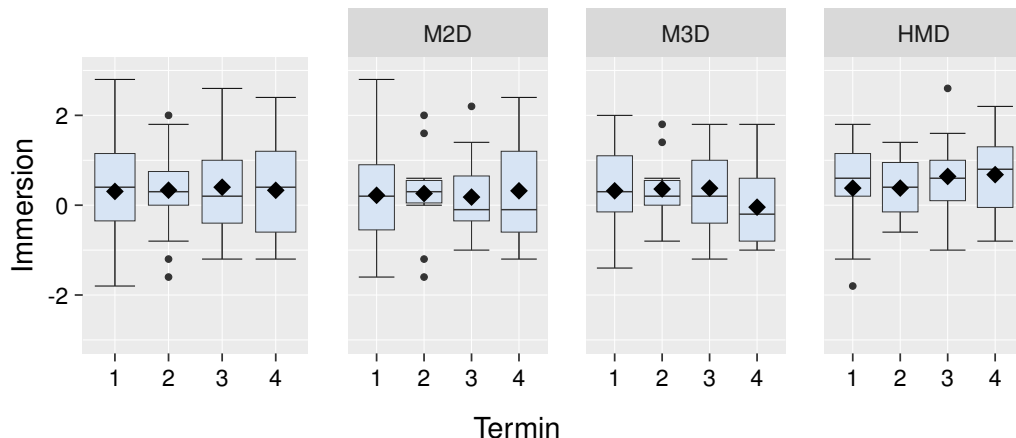


Abbildung 6.26: Immersion über Termin

Auch innerhalb der einzelnen Gruppen gibt es keinen signifikanten Effekt der Nutzungsdauer auf die Immersion und Präsenz (Anhang A.8.2). In der Gruppe HMD steigt deskriptiv die Immersion und Präsenz mit der Nutzungsdauer. Die höchste Immersion hatten Probanden in der HMD-Gruppe an Termin 4 ( $M_{T4,HMD}=0,068$ ), die niedrigste in der M3D-Gruppe an Termin 4 ( $M_{T4,M3D}=-0,04$ ).

#### 6.2.9 I. Sicherheitsgefühl

Zuletzt wurden die Probanden am Ende jeder Szene gefragt, wie sicher sie sich mit dem derzeitigen HMI in der Szene gefühlt hätten. Die Probanden können ihr Sicherheitsempfinden auf einer Skala von 1 bis 10 angeben, wobei 1 „unsicher“ und 10 „sehr sicher“ bedeutet.

Aufgrund der Ordinalskala ist eine Auswertung mit einem LMM nicht möglich, und es wird ein CLMM verwendet. Ähnlich wie LMM berücksichtigen CLMM zufällige Effekte. Die Proportional-

Odds-Voraussetzung wird über ein Modell mit allen Interaktionen validiert (Anhang A.9). Das Modell berücksichtigt die unabhängigen Variablen HMI, Qualität, Termin und Verkehrsaufkommen. Als zufällige Effekte werden die Variationen zwischen den Probanden und Szenen berücksichtigt. Die nachfolgenden Kapitel beschreiben die Einflüsse der jeweiligen unabhängigen Variablen auf das Sicherheitsempfinden.

## I.1 Einfluss HMI

Deskriptiv hatten Probanden über alle Termine und Qualitäten das höchste Sicherheitsempfinden in der M2D-Gruppe mit  $M_{M2D}=7,13$ , gefolgt von der HMD-Gruppe mit  $M_{HMD}=6,93$  und der M3D-Gruppe mit  $M_{M3D}=5,9$  (Abbildung 6.27). Das CLLM berechnet keine signifikanten Unterschiede für die Gruppe HMD ( $\beta_1=-0,207$ ,  $p=0,797$ ). Die Gruppe M2D hat einen tendenziellen Effekt ( $\beta_1=-1,577$ ,  $p=0,052$ ) auf das Sicherheitsempfinden der Probanden.

Die Nullhypothese  $H_{I,1}$  (Das HMI hat keinen Einfluss auf das Sicherheitsempfinden) ist anzunehmen.




Abbildung 6.27: Sicherheitsgefühl über die drei Gruppen

## I.2 Einfluss Qualität

Über alle Termine und Gruppen hatten die Probanden in den Szenen mit hoher Qualität ein durchschnittliches Sicherheitsempfinden von  $M_H=6,78$  und in den Szenen mit niedriger Qualität  $M_N=6,55$ . Die Qualität zeigt insgesamt keinen signifikanten Effekt auf das Sicherheitsempfinden der Probanden ( $\beta_1=-0,151$ ,  $p=0,274$ ).

Auch innerhalb der einzelnen Gruppen ist kein signifikanter Effekt der Qualität feststellbar. Deskriptiv wurde das höchste Sicherheitsempfinden in der M2D-Gruppe mit der hohen Qualität erreicht  $M_{M2D,H}=7,19$  und das niedrigste in der M3D-Gruppe mit der niedrigen Qualität  $M_{M3D,N}=5,74$ .

Die Nullhypothese  $H_{I,2}$  (Die Qualität hat keinen Einfluss auf das Sicherheitsempfinden) ist anzunehmen.




Abbildung 6.28: Sicherheitsgefühl über Qualität

### I.3 Einfluss Termin

Deskriptiv ist über alle Gruppen und Qualitäten ein Aufwärtstrend im Sicherheitsempfinden über die einzelnen Termine festzustellen. Am ersten Termin wird das Sicherheitsempfinden mit durchschnittlich  $M_{T_1}=6,29$  bewertet. Am zweiten und vierten Termin mit  $M_{T_2,T_4}=6,68$  und am dritten mit  $M_{T_3}=7,03$ . Der Effekt des dritten Termins ist über alle Gruppen stark **signifikant** ( $\beta_1=0,863$ ,  $p=1,77e-5$ ). Die Termine zwei ( $\beta_1=0,337$ ,  $p=0,096$ ) und drei ( $\beta_1=0,371$ ,  $p=0,063$ ) zeigen eine schwache Ablehnung der Nullhypothese.

Die Betrachtung der einzelnen Gruppen zeigt eine starke **Signifikanz** des dritten Termins in der M2D-Gruppe ( $\beta_1=1,222$ ,  $p=0,000$ ) sowie des zweiten ( $\beta_1=1,021$ ,  $p=0,008$ ) und dritten ( $\beta_1=0,887$ ,  $p=0,020$ ) Termins in der M3D-Gruppe. In der HMD-Gruppe ist keiner der Termine signifikant.

Rein deskriptiv wurde das höchste Sicherheitsempfinden an Termin drei mit  $M_{M2D,T_3}=7,59$  in der M2D-Gruppe erreicht und das niedrigste mit  $M_{M3D,T_1}=5,29$  an Termin eins in der M3D-Gruppe (Abbildung 6.29).

Die Nullhypothese  $H_{I,3}$  (Die Nutzungshäufigkeit des HMI hat keinen Einfluss auf das Sicherheitsempfinden) ist abzulehnen.




Abbildung 6.29: Sicherheitsgefühl über die Termine

## I.4 Einfluss Verkehrsaufkommen

Als weiteren Faktor für das Sicherheitsempfinden wird das Verkehrsaufkommen untersucht. Das Verkehrsaufkommen in jeder Szene wird subjektiv in die Stufen niedrig, mittel und hoch eingestuft. Abbildung 6.30 zeigt das Sicherheitsgefühl in Abhängigkeit der Szenen und der Einstufung des Verkehrsaufkommens. Es ist ersichtlich, dass die Szenen mit niedrigem Verkehrsaufkommen eine höhere Bewertung erhalten als die Szenen mit mittlerem oder hohem Verkehrsaufkommen. Beide Stufen zeigen einen stark **signifikanten** Effekt auf das Sicherheitsempfinden mit ( $\beta_1=-1,050$ ,  $p=0,001$ ) für das mittlere und ( $\beta_1=-1,303$ ,  $p=0,001$ ) für das hohe Verkehrsaufkommen.

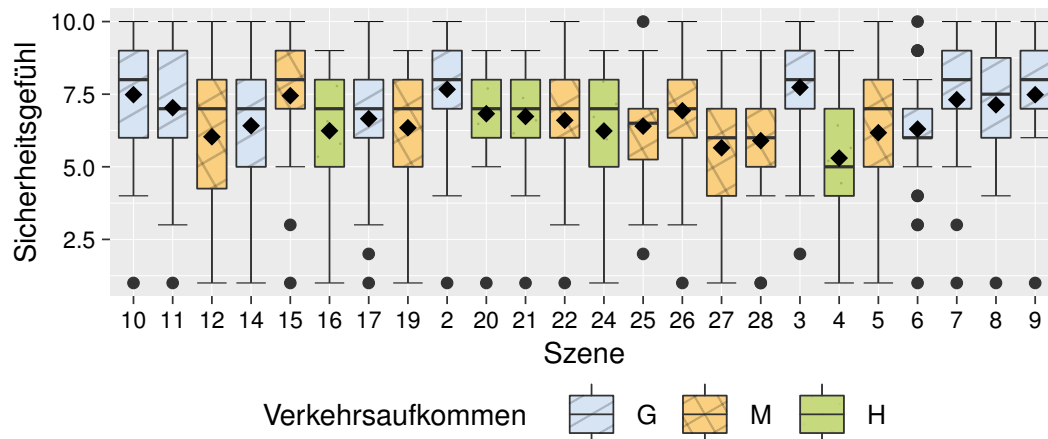


Abbildung 6.30: Sicherheitsgefühl über Verkehrsaufkommen. Die Skala reicht von G: Gering (0-3 Verkehrsteilnehmer), über M: Mittel (4-7 Verkehrsteilnehmer), bis hin zu H: Hoch (8 oder mehr Verkehrsteilnehmer).

### 6.2.10 Direkter Vergleich

Am vierten Termin werden den Probanden zusätzlich zu den Szenen und dem Abschlussfragebogen eine weitere lange Szene mit den bis dahin unbekanntem HMI gezeigt. Im Anschluss werden die Probanden aufgefordert, ihr favorisiertes HMI zu wählen. Abbildung 6.31 links zeigt die ursprüngliche Gruppenkonstellation und den Wechsel der Probanden zwischen den Gruppen. Rechts ist die Anzahl der Probanden zu sehen, die sich für das jeweilige HMI entschieden haben. Das HMD wird von mehr als 50% der Probanden bevorzugt. Als Gründe werden realistischere

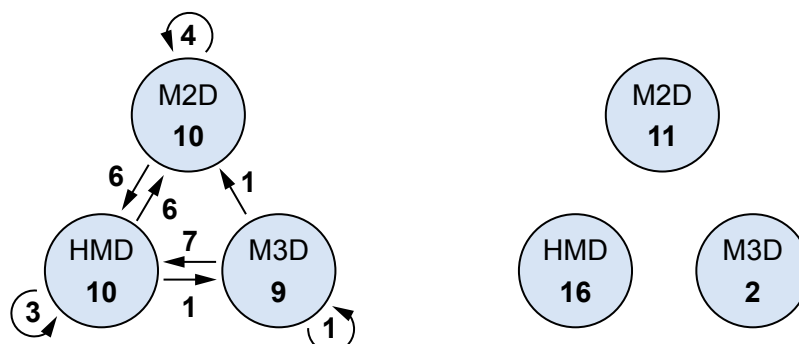


Abbildung 6.31: Links: Probandenkonstellation zu Beginn des Vergleichs und Wechsel zwischen den Gruppen. Rechts: Präferenz der Probanden nach dem Vergleich. [263]

Blickwinkel, bessere Erkennbarkeit bestimmter Stellen, die Möglichkeit des Schulterblicks, eine schärfere Seitenansicht und eine höhere Immersion genannt. Für die M3D-Gruppen entscheiden sich lediglich zwei Probanden, die das HMD als unbequem bzw. anstrengend empfinden. Sieben

Probanden aus der Gruppe M3D haben keine Probleme mit dem HMD und entscheiden sich für dieses HMI. Probanden, die sich für die M2D-Gruppen entscheiden, geben an, sich aufgrund des großen Blickwinkels und der geringen Verzerrung für das M2D-HMI entschieden zu haben, merken jedoch auch an, dass dieses HMI aufgrund der Dopplung im Bild am meisten Training erfordert.

Zuletzt haben die Probanden erstmalig die Möglichkeit, mit dem realen Fahrzeug teleoperiert zu fahren. Insgesamt neun der 29 Probanden nehmen diese Möglichkeit wahr und teleoperieren das Fahrzeug auf einem abgeschlossenen Rundparcours. Die Probanden werden aufgefordert, das Fahrzeug mit den verschiedenen HMI zu teleoperieren und im Anschluss ihre Präferenz zu nennen. Abbildung 6.32 zeigt links die Probandenkonstellation innerhalb der ursprünglichen Gruppen und rechts das favorisierte HMI nach der Fahrt. Von fünf Probanden, die den gesamten Versuch mit dem HMD absolviert haben, entscheiden sich vier weiterhin für dieses HMI. Durch das HMD geben die Probanden an, haben sie das Gefühl, sich im realen Fahrzeug zu befinden. Zusätzlich wird das Training mit der Brille als positiver Aspekt genannt. Für die M3D-Gruppe hat sich ein Proband entschieden und für die M2D-Gruppe drei Probanden. Hier wird insbesondere die sichtbare Motorhaube gelobt, die das Einschätzen der Breite des Fahrzeugs erleichtert. Weiter wurde die geringe Verzerrung und das große Sichtfeld der Seitenkameras als positiv bewertet.




Abbildung 6.32: Links: Probandenkonstellation am Anfang des Vergleichs und Wechsel zwischen den Gruppen. Rechts: Präferenz der Probanden nach dem Vergleich. [263]

### 6.2.11 Zusammenfassung und Diskussion

Die vorherigen Kapitel beschreiben die statistische Auswertung des Effekts der unabhängigen Variablen auf verschiedene Aspekte während der Teleoperation sowie die subjektive Präferenz der Probanden für ein HMI. In diesem Kapitel wird die Studie sowie die Ergebnisse zusammengefasst und über die statistischen Ergebnisse hinaus interpretiert.

Das Ziel der Studie ist es, objektiv die Auswirkungen verschiedener HMI, der Videoqualität und der Nutzungsdauer auf die Teleoperation von HAF zu quantifizieren sowie subjektive Präferenzen zu erfassen. Hierzu wird ein In-Between-Group-Design mit drei Gruppen verwendet. Die Gruppen unterscheiden sich in der Art der Darstellung der Kamerabilder sowie des verwendeten Anzeigegeräts. Jedem Probanden werden an vier Terminen sowohl kurze als auch lange Szenen gezeigt. Es wird das Situationsbewusstsein durch die SAGAT-Methode [141] gemessen sowie verschiedene subjektive Messwerte durch weitere Fragebögen erfasst. Die letzten Termine beinhalten einen direkten Vergleich der HMI mit aufgezeichneten Daten sowie optional eine real teleoperierte Fahrt mit dem Fahrzeug.



Tabelle 6.1 zeigt eine Übersicht der Ergebnisse der statistischen Auswertung. Die Tabelle visualisiert die signifikanten Effekte der unabhängigen Variablen auf die abhängigen Variablen und ermöglicht es, ein umfassendes Bild der Studienergebnisse zu erlangen. In den folgenden Unterkapiteln werden die Effekte der einzelnen unabhängigen Variablen diskutiert.

Tabelle 6.1: Übersicht der Studienergebnisse inkl. Richtung der Änderung (hoch: positiv, runter: negativ) und einzelnen Faktoren („-“ nicht signifikant,  $\Delta$ / $\nabla$  Tendenz  $p < 0.1$ ,  $\blacktriangle$ / $\blacktriangledown$  signifikant  $p < 0.05$ ,  $\blacktriangle\blacktriangle$ / $\blacktriangledown\blacktriangledown$  signifikant  $p < 0.01$ )

Unabhängige Var. Abhängige Var.	HMI	Qualität				Termin		HMI	
		Insgesamt	M2D	M3D	HMD	Insgesamt	M2D	M3D	HMD
A. Verkehrsteilnehmer	$\nabla$ M3D	-	-	-	$\nabla$ N	$\blacktriangle$ T3	$\nabla$ T4	-	-
B. Verkehrsschilder	-	-	-	-	-	$\blacktriangle$ T4	-	-	$\Delta$ T4
C. Geschwindigkeit	-	-	-	-	-	-	-	$\blacktriangledown\blacktriangledown$ T4	-
D. Spur	-	$\nabla$ N	-	$\blacktriangledown$ N	-	-	$\blacktriangledown$ T2	$\blacktriangledown$ T4	-
E. Vorhersage	-	$\blacktriangledown$ N	-	-	$\nabla$ N	-	-	-	$\Delta$ T4
F. Usability	-	-	-	-	-	$\blacktriangle\blacktriangle$ T2-3	-	$\Delta$ T2, $\blacktriangle$ T3	$\blacktriangle$ T4
G. Workload	-	-	$\nabla$ N	-	-	$\blacktriangle$ T2	$\Delta$ T2, $\blacktriangle\blacktriangle$ T3	$\blacktriangle$ T2	-
H. Immersion	-	-	$\blacktriangledown$ N	-	-	$\blacktriangle\blacktriangle$ T3,4	$\blacktriangle$ T4	$\blacktriangle\blacktriangle$ T3,4	$\Delta$ T4
I. Sicherheitsempfinden	$\nabla$ M3D	-	-	-	-	$\Delta$ T2,4	$\blacktriangle\blacktriangle$ T3	$\blacktriangle\blacktriangle$ T2	-
						$\blacktriangle\blacktriangle$ T3		$\blacktriangle$ T3, $\Delta$ T4	

## Faktor HMI

Der Faktor HMI hat bei der Betrachtung ohne Interaktion mit anderen Faktoren keine signifikanten Effekte auf die abhängigen Variablen. Die Probanden haben mit allen drei HMI ein vergleichbares Situationsbewusstsein erreicht. Auch die Bewertung der subjektiven Messgrößen zeigt keine signifikanten Unterschiede zwischen den HMI.

Die Betrachtung der deskriptiven Statistik zeigt, dass die Probanden in der M2D, gefolgt von der HMD-Gruppe, im Durchschnitt bessere Ergebnisse erzielt haben als Probanden in der M3D-Gruppe. Dies wird bestärkt durch tendenziell schlechtere Ergebnisse bei der Erkennung von Verkehrsteilnehmern und dem Sicherheitsempfinden der Probanden. Obwohl die HMI sich deutlich voneinander unterscheiden, sind diese Unterschiede rein tendenziell und könnten durch Zufall, z. B. in der Probandenkonstellation, entstanden sein.

Eine mögliche Erklärung für den fehlenden Unterschied ist die Abstraktions- und Transferleistung der Probanden. Den Probanden war es mit allen HMI möglich, auch in komplexen Situationen ein korrektes mentales Modell der Situation zu generieren und das für diese Szene erforderliche Situationsbewusstsein zu erreichen. Die hierfür notwendige mentale Leistung hat keinen signifikanten Unterschied im Workload herbeigeführt. Hierdurch wird bestärkt, dass der Faktor HMI objektiv keinen Einfluss auf das Situationsbewusstsein während der Teleoperation hat, weil die Probanden ohne Anstrengung mit allen HMI eine ähnliche Leistung erbracht haben.

Zusammengefasst lässt sich keine Aussage auf Basis dieser Daten treffen, welche Darstellungsform für die Teleoperation besser geeignet ist. Es ist wahrscheinlicher, dass andere Faktoren wie Kameraplatzierung, Kameranzahl oder FOV einen größeren Einfluss auf das Situationsbewusstsein haben als die Darstellungsform oder das Darstellungsgerät der Kamerabilder an sich.

### Faktor Qualität

Der Faktor Qualität hat sowohl in der Betrachtung mit als auch ohne Interaktion signifikante Effekte auf die abhängigen Variablen. So konnte ein insgesamt signifikant negativer Effekt der Qualität auf die Vorhersagegüte der Probanden festgestellt werden. Eine mögliche Begründung hierfür ist, dass die Vorhersage der zukünftigen Situation erfordert, weit entfernte Objekte korrekt zu erkennen. Diese sind tendenziell kleiner und werden durch niedrigere Qualität stärker verpixelt, was eine Verschlechterung der Leistung begründen könnte.

Weitere signifikante Effekte treten bei der Schätzung der Spur in der M3D-Gruppe sowie der Immersion in der M2D-Gruppe auf. Auch tendenziell negative Effekte im Workload und der Erkennung von Verkehrsteilnehmern zeigen einen negativen Effekt der Qualität. Rein deskriptiv haben Probanden mit der niedrigen Qualität im Durchschnitt konsistent schlechtere Ergebnisse erzielt als mit der hohen Qualität. Auch wenn diese Effekte nicht in allen Messgrößen signifikant sind, zeigen sie, dass die Qualität einen Einfluss auf gewisse Aspekte der Teleoperation hat.

Eine mögliche Ursache für weitere fehlende signifikante Effekte ist das gewählte untere Qualitätsniveau. Die niedrige Qualität wurde auf Basis realistischer Annahmen gewählt. Es ist jedoch nicht auszuschließen, dass Situationen mit nicht ausreichender Konnektivität eine noch schlechtere Qualität erfordern, um einen stabilen Videostream gewährleisten zu können.

### Faktor Termin

Der Faktor Termin hat den stärksten Effekt auf nahezu alle abhängigen Variablen. Bei der Betrachtung der abhängigen Variablen, die das Situationsbewusstsein messen, treten sowohl negative als auch positive Effekte auf. Ausschließlich positive Effekte hingegen treten in der Usability, dem Workload und dem Sicherheitsempfinden auf. Die Probanden haben mit zunehmender Nutzungsdauer eine bessere Usability, eine geringere mentale Belastung und ein höheres Sicherheitsgefühl wahrgenommen.

Bei Betrachtung der Usability zeigt sich, dass vor allem in der M3D-Gruppe Probanden das HMI über die Nutzungsdauer besser bewertet haben, was für eine größere notwendige Eingewöhnungszeit spricht. Verglichen mit dem M2D-HMI, das in jedem Termin eine ähnliche Usability-Bewertung erhalten hat, ist dies ein Anzeichen dafür, dass Probanden in dieser Gruppe das HMI am natürlichsten empfunden haben, weil es keine Eingewöhnungszeit benötigt hat. Auch beim HMD gab es eine steigende Tendenz der Usability, die sich jedoch erst an Termin vier signifikant von Termin eins unterscheidet. Sowohl beim M3D- als auch beim HMD-HMI ist eine Steigerung der Usability an Termin vier zu erkennen, was darauf hindeutet, dass eine weitere Verbesserung der Usability durch eine längere Nutzungsdauer nicht auszuschließen ist.

Der Workload hat sich über die Nutzungsdauer vor allem in der M2D- und M3D-Gruppe signifikant verringert. In der HMD-Gruppe zeigt sich hingegen nur eine Tendenz eines verringerten Workloads an Termin vier. Eine mögliche Erklärung könnte die zusätzliche Belastung durch das HMD sein, die eine Reduzierung des Workloads durch die Nutzungsdauer überlagert. Auch beim Workload ist eine weitere Verbesserung mit längerer Nutzungsdauer nicht auszuschließen. Die größte Verbesserung beim Workload ist in der M3D-Gruppe zu erkennen, die am ersten Termin mit dem insgesamt höchsten Workload beginnt und am letzten Termin mit dem insgesamt niedrigsten Workload endet. Dies könnte durch die zunächst ungewohnte Darstellung der M3D-Gruppe begründet sein, an die sich die Probanden über die Nutzungsdauer gewöhnen und am Ende durch das Stitching der Sensordaten sogar einen geringeren Workload erreichen als in der M2D-Gruppe.

Zuletzt hat die Nutzungsdauer einen Effekt auf das Sicherheitsempfinden der Probanden. Je länger die Probanden das HMI genutzt haben, desto sicherer haben sie sich gefühlt. Dieser Effekt ist vor allem in der M3D-Gruppe signifikant, in der das Sicherheitsempfinden über die Termine steigt und erst am Ende des Versuchs ein ähnliches Niveau erreicht wie in der M2D- oder HMD-Gruppe. Hier schienen die Probanden sich am meisten an das HMI gewöhnen zu müssen, was auch an den deskriptiv geringen Mittelwerten der M3D-Gruppe zu erkennen ist.

## **Faktor Verkehrsaufkommen**

Ein weiterer Faktor, der in Bezug auf das Sicherheitsempfinden untersucht wird, ist das Verkehrsaufkommen. Die Auswertung zeigt, dass das Sicherheitsempfinden der Probanden mit zunehmendem Verkehrsaufkommen sinkt. Dieser Effekt ist in allen drei HMI-Gruppen signifikant und zeigt, dass die Probanden sich in Situationen mit höherem Verkehrsaufkommen unsicherer fühlen, weil die Wahrscheinlichkeit für eine potenziell gefährliche Situation steigt. Den Probanden war es folglich möglich, die Situationen mit höherem Verkehrsaufkommen zu erkennen und diese auch als potenziell gefährlicher einzustufen. Alle HMI konnten die Komplexität der Szene transportieren. Durch das verringerte Sicherheitsempfinden wird kein falsches Sicherheitsgefühl vermittelt, das zu einer erhöhten Unfallgefahr führen könnte, sondern die Probanden wissen, dass sie sich in einer potenziell gefährlicheren Situation befinden und können entsprechend vorsichtig agieren.

## **Subjektiver Vergleich**

Der direkte Vergleich der HMI dient dazu, die subjektive Präferenz der Probanden zu ermitteln. Der Vergleich zeigt, dass sowohl mit den aufgezeichneten Szenen als auch mit dem realen Fahrzeug das HMD-HMI vom Großteil der Probanden bevorzugt wird, gefolgt von dem M2D und dem M3D-HMI. Vor allem die Fusion der Kameradaten und die Möglichkeit, sich natürlich umzusehen, wurden von den Probanden positiv hervorgehoben. Die Unbeliebtheit des M3D-HMI deckt sich weiterhin mit den objektiven Messwerten. Auch wenn der Faktor Gruppe keinen signifikanten Effekt auf die unabhängigen Variablen hat, sind die Mittelwerte in der M3D konsistent schlechter als in den anderen Gruppen. Diese subtilen, im Einzelnen nicht signifikanten Effekte addieren sich insgesamt zu einer Präferenz des HMD- und M2D- gegenüber dem M3D-HMI durch die Probanden. Dies zeigt, dass die gemessenen objektiven Werte auch eine subjektive Relevanz haben und die Probanden diese wahrnehmen.

## **Grenzen und Validität der Studie**

Zur Bewertung der Studie wird in diesem Kapitel das Studiendesign kritisch hinterfragt und die Grenzen der Studie aufgezeigt. Die Validität wird nach Brosius [281, S. 227-237] hinsichtlich der inneren und externen Validität diskutiert.

### **Innere Validität**

Ein Kernaspekt ist das verschachtelte Studiendesign zwischen den Faktoren Termin, Qualität und Gruppe. Da die Probanden sowohl Szenen in hoher als auch in niedriger Qualität gesehen haben, ist eine exakte Trennung dieser Variablen von den anderen nicht möglich. Zudem wurden die Probanden nicht über die Qualitätsunterschiede informiert, sodass eine schlechte Qualität auch Auswirkungen auf die subjektive Bewertung des HMI hatte. Einige Probanden gaben an,

das HMI aufgrund der schlechten Qualität schlechter bewertet zu haben. Obwohl die Variablen prinzipiell entkoppelt voneinander untersucht werden sollten, ist dies nicht vollständig gegeben.

In Bezug auf die Messmethoden wurde die objektive Methode SAGAT verwendet, jedoch wäre eine ergänzende subjektive Bewertung der Situation Awareness durch die Situational Awareness Rating Technique (SART) sinnvoll, um die Ergebnisse zu validieren und zu ergänzen. Der SAGAT-Fragebogen könnte außerdem eher die Gedächtnisleistung prüfen, statt ausschließlich die Situation Awareness zu erfassen [282, S. 3, 283, S. 45]. Die Situation Present Assessment Method (SPAM), bei der Abfragen mündlich und in Echtzeit während der normalen Aufgaben ausgeführt werden, könnte hier eine Alternative bieten und den zusätzlichen Vorteil bringen, dass die Szenen nicht extra gestoppt werden müssten [284, S. 130].

Die Zuweisung der Probanden zu den verschiedenen Testbedingungen erfolgte nach dem Prinzip des Matchings. Um eine Gleichverteilung dieser Merkmale innerhalb der Gruppen zu gewährleisten, wurden Personen aufgrund spezifisch identifizierter Merkmale Gruppen zugeordnet.

Da das Matching auf der Basis von Drillingspaaren erfolgt, kann dies zur Folge haben, dass andere Merkmale der Probanden innerhalb der Gruppen ungleich verteilt sind. Eine Alternative wäre eine randomisierte Gruppenverteilung, die durch zufällige Zuordnung die Wahrscheinlichkeit einer gleichmäßigen Merkmalsverteilung erhöht [281, S. 237–238]. Durch die Randomisierung können bekannte und unbekannte Störfaktoren kontrolliert werden. In zukünftigen Studien sollte daher die Stichprobengröße erhöht werden, um die Randomisierung der Probanden zu ermöglichen.

### **Externe Validität**

Die Messung der Immersion und Presence wurde jeweils nach der Nutzung des jeweiligen HMI durchgeführt. Die retrospektive Erfassung dieser Faktoren kann jedoch schwierig sein, und Riley [285, S. 53] weist auf den Nachteil des Presence-Fragebogens hin, der als nicht standardisiert gilt und somit den Vergleich erschwert. Darüber hinaus könnte die Aufforderung an die Probanden, ihre Gedanken während der Nutzung des HMI zu äußern, vor allem bei Verwendung eines HMD, als störend empfunden werden und das Gefühl der Immersion und Presence verringern.

Ebenfalls wichtig ist, dass die Studie nicht mit geschulten RO durchgeführt wurde, sondern mit Hilfe von freiwilligen Versuchspersonen. Ferner wurden aufgezeichnete reale Szenarien eingesetzt, anstatt tatsächlicher Fahrten, um die Wiederholbarkeit und Vergleichbarkeit zwischen den Versuchspersonen zu gewährleisten. Das Verhalten realer RO in realen Fahrsituationen könnte sich von dem Verhalten der Probanden in dieser Studie unterscheiden.

Die untersuchten HMI erfüllen die Anforderung, mit Sensorconfigurationen von unterschiedlichen HAF kompatibel zu sein. Insbesondere durch das Stitching und die Kameraprojektion können Unterschiede in der Sensorconfiguration kompensiert werden. Diese Annahme wird jedoch nicht überprüft. Die Übertragbarkeit auf weitere HAF ist somit nur theoretisch gegeben.

Weitere Faktoren neben den unabhängigen Variablen könnten die Ergebnisse dieser Studie beeinflusst haben. Zur Erhöhung der Aussagekraft weiterer Studien sollten ein stärkerer Fokus auf die Kontrolle von konfundierenden Variablen gelegt werden.

## 6.3 Design Studie 2: Präzise Steuerung

Das nachfolgende Kapitel und die darin besprochene Studie bauen auf den Studienarbeiten von Meyersieck [171] und Franke [260] auf. Zur Evaluierung der entwickelten HMI in Bezug auf die präzise Steuerung des Fahrzeugs wird die Studie aus der Voranalyse (Kapitel 5.1) im Rahmen einer Expertenstudie wiederholt. Die Ergebnisse in diesem Kapitel beinhalten zusätzlich als Referenzwert die Ergebnisse der Studie aus der Voranalyse.

### 6.3.1 Forschungsziel der Studie

In dieser Studie werden die Forschungsziele im Kontext der übergeordneten Forschungsfragen formuliert (F1-A): Welche visuellen Darstellungsformen und Anzeigegeräte sind geeignet, um ein geeignetes Level an Situationsbewusstsein zu erreichen? Sowie (F1-B): Wie können die Informationen aus Kamera- und LiDAR-Sensoren kombiniert werden, um die Tiefenwahrnehmung des RO zu verbessern? Ziel der Studie ist es, verschiedene HMI und ihren Einfluss auf die präzise Teleoperation eines realen Fahrzeugs in engen Szenarien zu untersuchen, die eine korrekte Einschätzung von Abständen zwischen dem teleoperierten Fahrzeug und den umliegenden Objekten erfordern. Verschiedene Studien haben aufgezeigt, dass die Tiefenwahrnehmung während der Teleoperation herausfordernd sein kann [172, S. 4, 234, S. 10, 286, S. 105]. Die entwickelten HMI sollen die Tiefenwahrnehmung des RO verbessern und somit eine verbesserte präzise Steuerung des Fahrzeugs ermöglichen.

### 6.3.2 Studienaufbau

#### Hypothesen

In diesem Kapitel werden die Hypothesen der Studie vorgestellt, die sich auf die Untersuchung des Einflusses der verschiedenen HMI auf die präzise Steuerung konzentrieren. Die Hypothesen dienen als Grundlage für die empirische Untersuchung, um die Forschungsfragen zu beantworten und mögliche Zusammenhänge zwischen den verschiedenen HMI und der präzisen Steuerung des Fahrzeugs zu untersuchen.

- $H_1$ : Es existiert kein Unterschied in der präzisen Steuerung des Fahrzeugs zwischen einem HMI mit fusionierten LiDAR-Daten und einem HMI ohne LiDAR-Daten.
- $H_2$ : Es existiert kein Unterschied in der präzisen Steuerung des Fahrzeugs zwischen einem HMI mit Top-Down-Kameras und einem HMI ohne Top-Down-Kameras.
- $H_3$ : Es existiert kein Unterschied in den wahrgenommenen Abständen zwischen einem HMI mit fusionierten LiDAR-Daten und einem HMI ohne LiDAR-Daten.
- $H_4$ : Es existiert kein Unterschied in den wahrgenommenen Abständen zwischen einem HMI mit Top-Down-Kameras und einem HMI ohne Top-Down-Kameras.
- $H_5$ : Es existiert kein Unterschied in der subjektiven Wahrnehmung zwischen einem HMI mit fusionierten LiDAR-Daten und einem HMI ohne LiDAR-Daten.
- $H_6$ : Es existiert kein Unterschied in der subjektiven Wahrnehmung zwischen einem HMI mit Top-Down-Kameras und einem HMI ohne Top-Down-Kameras.

### **Messeinrichtung und HMI Auswahl**

Der Versuch findet auf einem abgeschlossenen Testgelände der Technischen Universität München statt. Als Versuchsfahrzeug wird das in Kapitel 5.2.2 vorgestellte Fahrzeug verwendet sowie der in Abbildung 5.4 gezeigte Operatorarbeitsplatz. Zur Evaluierung der LiDAR-Datenfusion wird sowohl ein HMI mit als auch ein HMI ohne Fusion gewählt. Die Auswahl der zu evaluierenden HMI erfolgt auf Basis der in Kapitel 5.2.3 und 5.2.4 vorgestellten HMI. Im Rahmen einer Vorauswahl mit Experten des Lehrstuhls wird ein offener Quader mit abgerundeten Kanten (Form C, Abbildung 5.9) als Form gewählt, weil diese sowohl mit (Abbildung 5.17) als auch ohne LiDAR-Daten ein vergleichbares HMI ermöglicht. Die in Kapitel 5.2.4 vorgestellte Visualisierung des Velodyne LiDAR ist aufgrund des hohen Rauschens des Sensors und der erhöhten Latenz im Rahmen der Vorauswahl ausgeschieden.

### **Versuchsdesign und Versuchsaufbau**

Das Ziel der Studie ist die Evaluierung des Einflusses verschiedener HMI auf die präzise Steuerung des Fahrzeugs. Hierzu wird ein Within-Subjects-Design verwendet, in welchem jeder Proband jeder Bedingung ausgesetzt wird. Um Reihenfolgeeffekte zu vermeiden, wird die Reihenfolge der Bedingungen randomisiert.

Am Versuchstag werden die Probanden in das System eingewiesen und über die Ziele der Studie aufgeklärt. Anschließend absolviert jeder Proband mit jedem HMI zweimal den Parcours, der aus sechs alltäglichen Fahrscenarien besteht. Jedes Szenario erfordert eine genaue Einschätzung der Abstände zwischen dem Fahrzeug und den zu umfahrenden Objekten. Die Probanden werden aufgefordert, so nah wie möglich an den Hindernissen vorbeizufahren, ohne diese mit dem Fahrzeug zu berühren. Dies ist notwendig, um zu große Abstände zwischen dem Fahrzeug und den Hindernissen zu vermeiden. Als Hindernisse dienen gelbe Schaumstoffwürfel mit einer Kantenlänge von 50 cm, die bei einer Kollision keine Schäden am Fahrzeug verursachen. Jeweils zwei Würfel werden aufeinander gestapelt, um eine ausreichende Höhe zu erreichen. Die sechs Szenarien sind in Kapitel 5.1.3 detailliert beschrieben. Im Anschluss an jedes HMI füllt jeder Proband einen Fragebogen zur Messung subjektiver Kennwerte aus.

### **Objektive Daten**

Zur Bewertung der realen Fahrleistung werden objektive Kriterien verwendet. Hierzu dienen die vom Sicherheitsfahrer gemessenen Abstände zwischen dem Fahrzeug und den Hindernissen bzw. Haltelinien als objektive Messdaten. Das Ziel der Erfassung dieser Daten ist die Vergleichbarkeit zwischen den verschiedenen HMI. Die objektiven Kriterien unterscheiden sich für jedes Szenario.

In den Verkehrssituationen 1, 2 und 5 werden die lateralen Abstände zwischen dem Fahrzeug und den Hindernissen gemessen. In den Szenarien 3 und 6 wird der longitudinale Abstand zur Haltelinie erfasst. Da in den Szenarien 4 und 6 jeweils Hindernisse links und rechts vom Fahrzeug sind, wird lediglich differenziert, ob die Hindernisse von dem Fahrzeug berührt bzw. tatsächlich angefahren werden oder ob keine Kollision stattgefunden hat.

Die resultierende Differenz wird als Indikator für die Einschätzung der Abstände vom Fahrzeug zu den Objekten verwendet. Bei Haltelinien werden ebenfalls der geschätzte und der reale Abstand zwischen dem Fahrzeug und der Haltelinie gemessen. Da der Sicherheitsfahrer während der Fahrt für die Messung der Abstände zwischen dem Fahrzeug und den Hindernissen

verantwortlich ist, kann er diese lediglich abschätzen. Im Nahbereich (0 cm - 20 cm) wird eine Schätzgenauigkeit von 10 cm angenommen und im Fernbereich (> 20 cm) von 50 cm.

## Subjektive Daten

Zusätzlich zu den objektiven Kriterien werden auch subjektive Kriterien herangezogen. Diese werden im Anschluss an jedes HMI durch einen Fragebogen erfragt. Dieser umfasst den Workload und das Empfinden verschiedener subjektiver Kriterien des Fahrers. Diese Kriterien beschreiben die Realitätsnähe, Kontrollierbarkeit, das Empfinden zur Einschätzung von Abständen und die Intuitivität der Bedienung. Die Fragen werden auf einer neunstufigen Likert-Skala beantwortet.

## Probandenkollektiv

Die Ergebnisse aus der in Kapitel 6.1 durchgeführten Studie zeigen, dass die Nutzungsdauer einen signifikanten Effekt auf verschiedene Faktoren der Teleoperation hat. Die sich daraus ableitenden Anforderungen, eine statistisch sinnvolle Anzahl (min. 10) an Probanden über eine längere Zeit mit dem System zu trainieren, übersteigen den Umfang dieser Studie. Aus diesem Grund wird die Studie mit drei Experten vom Lehrstuhl für Fahrzeugtechnik durchgeführt. Die Probanden sind alle männlich, im Durchschnitt 27 Jahre alt und besitzen alle einen Führerschein.

## 6.4 Auswertung Studie 2: Präzise Steuerung

Die nachfolgenden Kapitel dienen der detaillierten Analyse und Diskussion der gesammelten objektiven und subjektiven Daten. Aufgrund der Probandenzahl wird dabei ein rein deskriptiver Analyseansatz verfolgt. Die einzelnen Abkürzungen für die jeweilige Gruppe sind: Gruppe C-HMD bezeichnet die Gruppe mit der statischen Form C und einem HMD. Probanden in der Gruppe L-HMD verwenden das fusionierte LiDAR HMI sowie ebenfalls ein HMD (Abbildung 6.33). Probanden in der Gruppe R-HMD bzw. R-M verwenden das Referenz-HMD bzw. Monitor-HMI. Aufgrund der unterschiedlichen Anzahl an Studienteilnehmern in dieser und der Referenzstudie werden die Ergebnisse auf alle in der jeweiligen Studie absolvierten Fahrten bezogen.




Abbildung 6.33: HMI Übersicht. Blaue Flächen repräsentieren Kameradaten, während dunkelblaue Quader und rote Punkte LiDAR-Daten darstellen.

### 6.4.1 Abstand zu seitlichen Hindernissen

Abbildung 6.34 zeigt für alle zutreffenden Situationen (1, 2, 5) ein Histogramm der realen seitlichen Abstände zwischen dem Fahrzeug und den Hindernissen sowie Boxplots des Schätz-

fehlers, der durch die Differenz zwischen dem realen und dem vom Probanden geschätzten Abstand berechnet wird. Eine Kollision wird mit  $-0,25$  m (halbe Würfelkantenlänge) und eine Berührung mit  $-0,1$  m gewertet. Probanden in der Gruppe C-HMD und L-HMD haben in 55,5 % bzw. 44,4 % aller Fahrten einen Abstand von weniger als  $0,1$  m erreicht. Probanden mit den HMI R-HMD und R-M haben in 16,7 % bzw. 8,3 % aller Fahrten einen Abstand von unter  $0,1$  m erreicht. Probanden mit dem HMI L-HMD hatten insgesamt am wenigsten Kollisionen.

Probanden mit den Referenz-HMI sind in 41,7 % der Fahrten mit einem Abstand zwischen  $0,2$  bis  $0,5$  m an den Hindernissen vorbeigefahren und haben als Einzige Abstände von mehr als  $0,5$  m erreicht.

Die wenigsten Kollisionen bzw. Berührungspunkte mit den Hindernissen haben Probanden in der L-HMD erreicht. Hier traten lediglich in 11,1 % der Fahrten Kollisionen auf, wohingegen in den anderen Gruppen in 16,7 % der Fahrten Kollisionen vorkamen.

Der rechte Teil der Abbildung 6.34 zeigt Boxplots der Differenz zwischen dem realen und dem empfundenen Abstand. Den geringsten Fehler in der Distanzschätzung machen Probanden mit  $M_{C-HMD}=0,18$  m in der C-HMD-Gruppe, gefolgt von Probanden in der R-HMD-Gruppe mit  $M_{R-HMD}=0,22$  m. Da die Voraussetzungen für die Verwendung von einem LMM erfüllt sind (Anhang A.10), kann die Distanzschätzung mit statistischen Modellen analysiert werden. Die Ergebnisse zeigen keine signifikanten Unterschiede zwischen den HMI. Es existiert ein tendenzieller Unterschied zwischen dem C-HMD- und R-M-HMI ( $\beta_1=0,180$ ,  $p=0,088$ ).

Insgesamt konnten Probanden mit dem C-HMD und L-HMD HMI, verglichen mit den Referenz-HMI, geringere Abstände zwischen dem Fahrzeug und den Hindernissen erzielen, ohne die Anzahl an Kollisionen zu erhöhen bzw. sogar zu verringern. Die Fusion der LiDAR-Daten hat zu weniger Kollisionen und Berührungen geführt, jedoch zu einer erhöhten Anzahl an Abständen zwischen  $0,1$  und  $0,2$  m. Dies bedeutet, dass Probanden einen etwas größeren Abstand zu den Hindernissen eingehalten haben. Eine eindeutige Bewertung, welches der HMI eine bessere Leistung erzielt hat, ist nicht möglich. Eine mögliche Ursache hierfür könnte sein, dass der LiDAR den seitlichen Bereich des Fahrzeugs nicht abdeckt.




Abbildung 6.34: Links: Abstände zu seitlichen Hindernissen je Gruppe. Rechts: Absoluter Schätzfehler je Gruppe in [m].



## 6.4.2 Abstand zwischen zwei Hindernissen

In den Fahraufgaben 4 und 6 müssen die Probanden jeweils zwischen zwei engen Hindernissen durchfahren bzw. parken. Diese Aufgabe erfordert sowohl das Einschätzen von seitlichen als auch von vorderen Abständen. Da bei diesen Aufgaben ein geringerer Abstand auf der einen Seite des Fahrzeugs einen größeren Abstand auf der anderen Seite bedeutet, wird ausschließlich eine Kollision bzw. eine Berührung gewertet. Abbildung 6.35 zeigt das an allen Fahrten anteilige Histogramm der jeweiligen Kategorien sowie den Fehler der Einschätzung. Probanden in den L-HMD-Gruppen haben in diesen Situationen mit 83,3 % kollisions- und berührungsfreien Fahrten die beste Leistung erzielt, gefolgt von Probanden in der C-HMD-Gruppe mit 66,7 %. Probanden in den Referenzgruppen erzielten in 37,5 % bzw. 43,8 % der Fälle eine fehlerfreie Fahrt.

Der rechte Teil der Abbildung zeigt einen Boxplot der Fehleinschätzung der Probanden. Es ist deutlich zu erkennen, dass Probanden in der C-HMD- und L-HMD-Gruppe eine geringere Fehleinschätzung der Abstände erzielen. Vor allem in der R-HMD-Gruppe hatten Probanden Probleme mit der Wahrnehmung der realen Abstände.

Insgesamt haben Probanden in der C-HMD-Gruppe und L-HMD-Gruppe bessere Ergebnisse erzielt als Probanden aus den Referenzgruppen. Probanden mit dem L-HMD haben insgesamt die besten Ergebnisse erzielt. Die Unterschiede zwischen L-HMD und C-HMD sind nicht groß genug, um eine genauere Aussage darüber treffen zu können, welches HMI mit einer besseren Leistung korreliert.

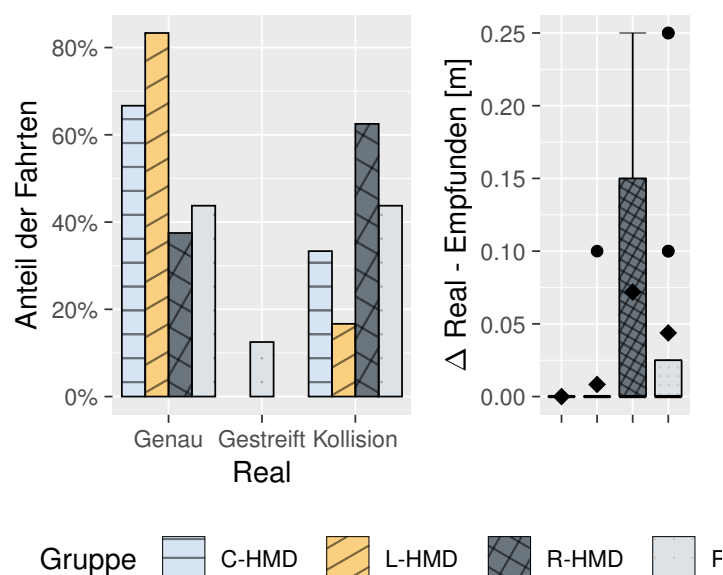


Abbildung 6.35: Abstände zwischen zwei Hindernissen je Gruppe

## 6.4.3 Abstand zu Haltelinien

In den Situationen 3 und 6 haben die Probanden die Aufgabe, an einer auf dem Boden aufgezzeichneten weißen Linie mit 5 cm Breite zu halten, sodass die vordere Stoßstange sich genau über der Linie befindet. Abbildung 6.36 zeigt die gemessenen Abstände zwischen der Linie und der Stoßstange.

Probanden in der C-HMD- und L-HMD-Gruppe konnten mit 58,3 % bzw. 75,0 % am häufigsten genau auf der Linie halten, während Probanden in der R-HMD- und R-M-Gruppe am häufigsten mit 43,8 % zwischen 0,5 und 1,0 m bzw. mit 37,5 % zwischen 0,2 und 0,5 m zum Stehen kamen.

Weiterhin erzielen Probanden in den C-HMD- und L-HMD-Gruppen einen geringeren Fehler in der Einschätzung der Distanzen zur Haltelinie ( $M_{C-HMD}=0,32$  m,  $M_{L-HMD}=0,28$  m) als Probanden aus der R-HMD- und R-M-Gruppe ( $M_{R-HMD}=0,5$  m und  $M_{R-M}=0,39$  m).




Abbildung 6.36: Abstände zur Haltelinie je Gruppe

### 6.4.4 Subjektive Bewertungsfaktoren

Zusätzlich zu den objektiven Messwerten füllen die Probanden nach der letzten Fahrt mit einem HMI einen Abschlussfragebogen [171, 260] aus. Dieser beinhaltet verschiedene Fragen




Abbildung 6.37: Links: Boxplots der Antworten des Abschlussfragebogens. Rechts: Boxplots des Workloads, gemessen mit dem NASA TLX Fragebogens [244].

zu subjektiven Eindrücken während der Teleoperation sowie die Messung des subjektiven Workloads anhand des NASA TLX [244]-Fragebogens. Abbildung 6.37 zeigt grafisch die Ergebnisse des Fragebogens. Deutliche Unterschiede zwischen den Gruppen existieren in der Straßenzulassung, dem Überblick, dem Vertrauen und dem Umgang mit dem System. In Bezug auf die Straßenzulassung erzielten die Gruppen C-HMD und L-HMD bessere Bewertungen als die Referenzgruppen. Die Gruppe C-HMD erhält in Bezug auf die Übersichtlichkeit die besten Bewertungen, während die anderen Gruppen ähnliche Bewertungen erhalten. Hier ist auffällig, dass die Gruppe L-HMD verglichen mit der C-HMD-Gruppe einen eher negativen Einfluss auf die Übersichtlichkeit hat. Das Vertrauen der Probanden in das System ist in den Gruppen C-HMD und L-HMD größer als in den Referenzgruppen. Bezüglich der Einschätzung der vorderen Abstände erhält das C-HMD die niedrigsten Bewertungen. Bei der Einschätzung der Fähigkeit der Probanden, von Anfang an gut mit dem System umzugehen, erzielten das C-HMD und das L-HMD bessere Bewertungen. Dies weist darauf hin, dass die Probanden diese HMI als benutzerfreundlicher einschätzen. Abschließend haben Probanden in der C-HMD- und L-HMD-Gruppe einen deutlich geringeren Workload als Probanden in den Referenzgruppen. Ein Unterschied zwischen dem Workload in der C-HMD- und L-HMD-Gruppe ist zu erkennen.

### 6.4.5 Zusammenfassung und Diskussion

In diesem Kapitel werden die individuellen Ergebnisse im Zusammenhang mit den Hypothesen diskutiert und zusammengefasst. Der Unterschied in der Leistung in allen drei Abstandskategorien zwischen dem C-HMD und dem L-HMDHMI ist weder eindeutig noch ausreichend, um eine konkrete Aussage treffen zu können. Daher wird Hypothese  $H_1$  (Es besteht kein Unterschied in der präzisen Steuerung des Fahrzeugs zwischen einem HMI mit und einem ohne fusionierte LiDAR-Daten) angenommen.

In allen drei Abstandskriterien erzielten Probanden aus der C-HMD- und L-HMD-Gruppe eine um den Faktor 2-3 bessere Leistung als Probanden aus der R-HMD- oder R-M-Gruppe. Daher wird Hypothese  $H_2$  (Es besteht kein Unterschied in der präzisen Steuerung zwischen einem HMI mit und ohne Top-Down-Kameras) abgelehnt.

Der Fehler bei der Schätzung der Abstände im Vergleich zu den realen Abständen ist für C-HMD und L-HMD HMI in allen drei Abstandskategorien ähnlich. Die jeweiligen LMM zeigen keinen signifikanten Effekt des HMI. Daher wird Hypothese  $H_3$  (Es besteht kein Unterschied in der wahrgenommenen Entfernung zwischen einem HMI mit und ohne fusionierten LiDAR-Daten) angenommen.

Der Vergleich der durchschnittlichen Fehler zwischen dem C-HMD und dem L-HMD HMI mit den R-HMD und R-M HMI zeigt sowohl beim Durchfahren von zwei Hindernissen als auch beim Halten an einer definierten Endposition deutliche Unterschiede. Daher wird die Hypothese  $H_4$  (Es besteht kein Unterschied in der präzisen Steuerung zwischen einem HMI mit Top-Down-Kameras und einem HMI ohne Top-Down-Kameras) abgelehnt.

Die subjektiven Daten zeigen bei der Übersicht und bei den vorderen Abständen deutliche Unterschiede zwischen dem C-HMD und L-HMD HMI. Beim Überblick wird das C-HMD und bei den vorderen Abständen das L-HMD HMI besser bewertet. Eine mögliche Erklärung könnte sein, dass durch die Projektion der LiDAR-Daten die Abstände nach vorne hin besser wahrgenommen werden können, während gleichzeitig die Videofläche verkleinert wird (Abbildung 5.17), was zu einem subjektiv schlechteren Überblick führt. Die Hypothese  $H_5$  (Es besteht kein Unterschied in

der subjektiven Wahrnehmung zwischen einem HMI mit fusionierten LiDAR-Daten und einem HMI ohne LiDAR-Daten) wird daher abgelehnt.

Der Vergleich der Referenz-HMI zeigt deutliche Unterschiede in der subjektiven Bewertung der Faktoren Straßenzulassung, Überblick, Handhabung und Vertrauen. Die Hypothese  $H_6$  (Es besteht kein Unterschied in der subjektiven Wahrnehmung zwischen einem HMI mit und ohne Top-Down-Kameras) wird daher abgelehnt.

### **Einfluss LiDAR-Daten**

Das L-HMD HMI wird ausschließlich mit dem C-HMD verglichen, weil mehrere Veränderungen zwischen dem L-HMD und dem Referenz-HMI eine isolierte Betrachtung des alleinigen Effekts der LiDAR-Datenvisualisierung nicht zulassen.

Die objektiven Daten zeigen in allen drei Abstandskategorien keinen signifikanten Unterschied zwischen dem C-HMD und dem L-HMD HMI. Ebenso ist kein Einfluss auf den Fehler der Abstandsschätzung zwischen den tatsächlichen und den wahrgenommenen Abständen ersichtlich.

Die subjektive Wahrnehmung der Probanden, mit dem C-HMD einen besseren Überblick und mit dem L-HMD HMI eine bessere Einschätzung der vorderen Abstände zu haben, findet keine Bestätigung in den objektiven Daten. Daraus folgt, dass die dreidimensionale Darstellung der LiDAR-Daten innerhalb des HMD gegenüber der reinen Visualisierung der Top-Down-Kameras keinen eindeutigen Einfluss auf die präzise Steuerung des Fahrzeugs oder die Tiefenwahrnehmung von Objekten in der Nähe des Fahrzeugs hat.

### **Einfluss Top-Down-Kameras**

Das C-HMD HMI wird mit dem R-HMD verglichen, weil mehrere Veränderungen zwischen dem C-HMD und dem R-M HMI eine isolierte Betrachtung des alleinigen Effekts der Top-Down-Kamera-Visualisierung nicht zulassen.

Sowohl die objektiven als auch die subjektiven Daten zeigen deutliche Unterschiede in allen relevanten abhängigen Variablen. In allen Abstandskategorien konnten Probanden mit dem C-HMD geringere Abstände zu Hindernissen und Haltelinien erreichen und insgesamt die Anzahl der Kollisionen reduzieren. Zudem ist eine Verbesserung der Fehlerdifferenz zwischen den wahrgenommenen und den tatsächlichen Abständen erkennbar. Sowohl beim Durchfahren von Hindernissen als auch beim präzisen Anhalten an einer Haltelinie konnten Probanden die Abstände besser abschätzen.

Die subjektiven Daten weisen eine Verbesserung in der Bewertung der Straßentauglichkeit, der Übersichtlichkeit, der Handhabung, des Vertrauens und der Arbeitsbelastung auf. Dagegen zeigt sich eine Verschlechterung in der Bewertung der vorderen Abstände, was allerdings nicht durch die tatsächlichen objektiven Daten bestätigt werden kann und im Widerspruch zur verbesserten Bewertung der Übersichtlichkeit steht. Insgesamt ergibt sich ein positiver Effekt des C-HMD HMI im Vergleich zum Referenz-HMI. Probanden können mit dem C-HMD die Abstände zwischen dem Fahrzeug besser einhalten, präziser an einer definierten Stelle anhalten und gleichzeitig eine bessere subjektive Erfahrung mit geringerem Workload haben.

## Validität der Studie

Die Validität wird nach Brosius [281, S. 227–237] hinsichtlich der inneren und äußeren Validität diskutiert. Die innere Validität beschreibt, welche Fehler während der Studie auftreten können. Die äußere Validität beschreibt, wie gut die Ergebnisse dieser Studie auf reale Anwendungen übertragbar sind.

### Innere Validität

Die Anzahl der Probanden ist mit drei Personen nicht ausreichend, um statistisch aussagekräftige Ergebnisse zu erzielen. Daher sind die Ergebnisse lediglich als Indikatoren zu sehen. Zudem besteht die Referenzgruppe (Vorstudie Kapitel 5.1) aus anderen Probanden als in dieser durchgeführten Studie, wodurch die Vergleichbarkeit der Gruppen beeinflusst werden kann. Ein Indikator hierfür ist, dass bei einigen subjektiven Fragen, bei denen keine Änderung durch das HMI zu erwarten war, keine Änderung festgestellt wurde. Andererseits wurde auch bei unabhängigen Variablen, bei denen eine Änderung zu erwarten war, keine Änderung festgestellt.

Die Studie zur Untersuchung des Langzeiteffekts und des Situationsbewusstseins (Kapitel 6.2) hat gezeigt, dass der Faktor Termin und somit die Nutzungsdauer des Systems einen signifikanten Effekt auf verschiedene Variablen der Teleoperation hat. Eine längere Nutzungsdauer könnte auch in dieser Studie von Vorteil sein, um eine bessere Leistung zu erzielen. Um die Vergleichbarkeit zwischen dieser Studie und der Referenzstudie (Kapitel 5.1) zu gewährleisten, wurde dennoch auf eine längere Trainingszeit verzichtet. Da sich die positiven Effekte einer längeren Nutzungsdauer auf alle getesteten HMI auswirken und der Fokus dieser Studie auf dem Vergleich der HMI liegt, nicht auf der optimalen Leistung der Probanden, ist die Vernachlässigung dieses Aspekts vertretbar.

Objekte, die weiter als 7 m von den Fahrzeugkonturen entfernt sind, werden aufgrund der Punktedichte des verwendeten LiDAR nicht für die Visualisierung der LiDAR-Daten berücksichtigt. Dies kann für weiter entfernte Objekte zu Inkonsistenzen in der Visualisierung führen. Da der Fokus dieser Studie auf Objekte innerhalb dieser Grenze liegt, ist nur eine minimale Auswirkung auf die Studienergebnisse zu erwarten.

Weitere Inkonsistenzen können durch die unterschiedliche Montierungsposition des LiDAR und der Kamera entstehen. Für eine optimale Projektion liegen der LiDAR und die Kamera im gleichen Fluchtpunkt. Eine bessere Anordnung der Sensoren kann zu einer präziseren und fehlerfreieren Darstellung führen.

### Externe Validität

Die in dieser Arbeit entwickelten Lösungen wurden auf Prototypenniveau entwickelt und erfüllen keine Anforderungen der funktionalen Sicherheit, die für die Verwendung des Systems in realen Verkehrsszenarien vorausgesetzt werden. Die Ergebnisse dieser Studie können somit ausschließlich als Indikatoren für die Entwicklung straßentauglicher Systeme dienen.

Das in dieser Arbeit vorgestellte System wurde speziell für den Audi Q7 entwickelt, der vom Lehrstuhl für Fahrzeugtechnik für die Teleoperation verwendet wird. Dies bedeutet, dass das System nicht universell einsetzbar ist und die Ergebnisse nicht ohne Anpassungen auf andere Fahrzeugmodelle übertragen werden können. Die in dieser Arbeit behandelten Probleme und Lösungen sind jedoch allgemein genug, um in ähnlichen Projekten und Kontexten anwendbar zu sein. Insbesondere die Methoden zur Generierung der Visualisierung sind unabhängig von

spezifischen Fahrzeugmodellen oder -systemen und können auf andere Kontexte übertragen werden.

Für die Messung einiger subjektiver Daten, z. B. Straßenzulassung, Intuitivität, wird kein standardisierter Fragebogen verwendet. Dies erschwert die Vergleichbarkeit zwischen verschiedenen Systemen und anderen Studien.

# 7 Diskussion und Ausblick

In diesem Kapitel erfolgt eine vertiefende Diskussion und allgemeinere Interpretation der Entwicklungen im Bereich der Mensch-Maschine-Schnittstellen für die Teleoperation automatisierter Fahrzeuge. Zusätzlich werden daraus zukünftige Forschungsthemen abgeleitet. Eine Diskussion der durchgeführten Studien ist in Kapitel 6.2.11 und Kapitel 6.4.5 zu finden.

## 7.1 Übertragbarkeit auf andere Steuerungskonzepte

Primärer Fokus dieser Arbeit ist das Steuerungskonzept der direkten Steuerung bzw. des Remote Driving. Die SAE [28] definiert weitere Steuerungsarten wie Remote Assistance und Remote Monitoring, die in dieser Arbeit nicht untersucht werden. In Deutschland wird die direkte Steuerung im Gesetzesentwurf zum autonomen Fahren [287] nicht berücksichtigt. Der Fokus liegt auf der technischen Aufsicht, die es dem RO im Regelfall nur erlaubt, von dem Fahrzeug vorgeschlagene Manöver anzunehmen [287, S. 2] oder alternativ dem Fahrzeug Manöver vorzugeben, die selbstständig vom Fahrzeug ausgeführt werden [287, S. 30].

Dies unterstreicht die Notwendigkeit, die verschiedenen Steuerungsarten und ihre jeweiligen Anforderungen an das HMI zu betrachten. Obwohl die in dieser Arbeit gewonnenen Erkenntnisse auf verschiedene Steuerungsarten übertragbar sein könnten, ist zu erwarten, dass jede dieser Steuerungsarten ein spezifisches HMI benötigt, um die erforderlichen Informationen für den RO bereitzustellen. Während die direkte Steuerung eine intensivere Interaktion und möglicherweise eine detailliertere Informationsübermittlung erfordert, konzentriert sich die technische Aufsicht auf die Überwachung und gelegentliche Eingriffe, was ein unterschiedliches Design und Funktionsumfang des HMI impliziert. So hat Feiler [138] beispielsweise ein HMI für die Modifizierung der maschinellen Wahrnehmung entwickelt. Diese unterschiedlichen Anforderungen sollten bei der Entwicklung zukünftiger HMI für autonome Fahrzeuge berücksichtigt werden, um eine effiziente und sichere Bedienung in verschiedenen Kontexten der Teleoperation zu gewährleisten.

## 7.2 Berufsoperatoren

In den letzten Jahren haben sich die ersten kommerziellen Anwendungen der Teleoperation in der Fahrzeugtechnik entwickelt. Diese Anwendungen reichen von Car-Sharing-Lösungen für den öffentlichen Raum [83] bis hin zu Terminal-Zugmaschinen für Häfen [80]. Sie ermöglichen erstmals die Durchführung von Studien mit Berufsoperatoren, die bereits Erfahrung mit einem Teleoperationssystem gesammelt haben. Die in dieser Arbeit durchgeführten Studien konnten aufgrund der äußeren Rahmenbedingungen nicht mit Berufsoperatoren durchgeführt werden.

Um aussagekräftigere Ergebnisse zu erzielen, sollten zukünftige Studien mit Probanden aus der jeweiligen Zielgruppe erfolgen.

Weiterhin wurden die Nutzungsdauer und der Trainingseffekt als einer der Hauptfaktoren identifiziert, die einen Einfluss auf verschiedene Aspekte der Teleoperation haben. Es ist derzeit unklar, wie das Training eines RO gestaltet werden muss, um sicherzustellen, dass dieser die Fahrtätigkeit sicher bewältigen kann. Weitere Arbeiten sind notwendig, um zu verstehen, wie sich das Fahrverhalten eines RO über die Trainingszeit entwickelt und wann dieses ein Leistungsplateau erreicht.

Es ist auch von Interesse, die psychologischen und physiologischen Auswirkungen langfristiger Teleoperation auf die Operatoren zu untersuchen. Langzeitstudien könnten Aufschluss darüber geben, wie sich Faktoren wie Ermüdung, Stress und kognitive Belastung auf die Leistung und das Wohlbefinden der Operatoren auswirken.

### 7.3 Übertragung weiterer Sensormodalitäten

Diese Arbeit konzentriert sich hauptsächlich auf die durch den visuellen Sinn hervorgerufene Immersion. Die Ergebnisse dieser Arbeit zeigen, dass die Probanden keine vollständige Immersion erreicht haben (Kapitel 6.2.8). Um die Immersion zu erhöhen, kann die Übertragung weiterer Sensordaten förderlich sein [146, S. 55]. Beispielsweise könnten Beschleunigungsdaten des Fahrzeugs dazu verwendet werden, die Straßenbedingungen am Arbeitsplatz des RO zu simulieren. Mikrofone können zur Übertragung der Umgebungsgeräusche eingesetzt werden, um eine akustische Dimension der Immersion zu schaffen. Weiterhin können Lenkmotordaten erfasst werden, um ein realistischeres Lenkgefühl zu reproduzieren [288]. Zukünftige Forschungsarbeiten sollten daher die Auswirkungen der Übertragung weiterer Sensormodalitäten auf verschiedene Aspekte untersuchen. Dazu gehört nicht nur die Immersion, sondern auch das Situationsbewusstsein und das Gefühl, sich physisch am entfernten Ort zu befinden.

### 7.4 Entwicklungsstand von HMD

Die Ergebnisse dieser Arbeit zeigen, dass Probanden ein HMD gegenüber konventionellen Monitoren bevorzugen. Aufgrund der Rahmenbedingungen dieser Arbeit haben die Probanden das HMD maximal eine Stunde am Stück getragen. Auch wenn Studien zeigen, dass sich zumindest bei Kindern keine negativen Effekte bei der Nutzung eines HMD für eine Stunde oder mehr ergeben [289], müssen zukünftige RO eventuell mehrere Stunden am Tag ein entsprechendes HMD verwenden können. Aufgrund der fehlenden Möglichkeit, reale RO einem solchen System zu exponieren, kann derzeit keine Aussage darüber getroffen werden, ob ein RO ein HMD im Alltag produktiv verwenden kann.

Gleichzeitig ist aufgrund der kontinuierlichen Entwicklung von HMD eine Verbesserung der Technologie und Ergonomie zu erwarten. Beispielsweise hat Apple in den letzten fünf Jahren Investitionen von über 20 Milliarden Dollar in die Entwicklung eines neuen HMD getätigt [290]. Neue HMD und deren bessere Verfügbarkeit können langfristig zu einer höheren Akzeptanz und Gewöhnung führen. Zukünftige Arbeiten sollten ganzheitlich die Langzeiteffekte und Vorteile solcher HMD untersuchen.



## 8 Zusammenfassung

In diesem Kapitel wird diese Arbeit zusammengefasst, die Forschungsfragen abschließend beantwortet und ein Ausblick auf mögliche weitere Fragestellungen gegeben. Diese Forschungsarbeit beschäftigt sich mit der Entwicklung eines HMI und einer Sensordatenfusion für die Teleoperation von automatisierten Fahrzeugen. Hierbei ist die Teleoperation die letzte Rückfallebene im Fall von Fehlern des automatisierten Systems. Diese Fehler, die jederzeit im Betrieb der Fahrzeuge auftreten können, können durch verschiedene Arten der Teleoperation behoben werden, wobei Remote Driving als letzte Rückfallebene betrachtet wird. In allen Arten der Teleoperation muss der Remote Operator, auf Basis der übermittelten Sensorinformationen des Fahrzeugs, Situationsbewusstsein und ein mentales Modell der Umgebung aufbauen. Hierzu nutzt der Remote Operator das vom System bereitgestellte HMI. Die korrekte und verständliche Darstellung der Sensorinformationen auf dem HMI hat folglich Auswirkungen auf die Richtigkeit der vom Remote Operator getroffenen Entscheidungen.

Die Recherche dieser Arbeit zeigt, dass es einzelne Studien in verschiedenen Bereichen der Teleoperation gibt, deren Ergebnisse jedoch nur teilweise auf das HMI für die Teleoperation von hochautomatisierten Fahrzeugen übertragbar sind. Vor allem die Vielzahl an unterschiedlichen Sensoren sowie die komplexen, im alltäglichen Straßenverkehr vorkommenden Situationen unterscheiden die Teleoperation von hochautomatisierten Fahrzeugen von anderen Teleoperationssystemen und erschweren die Aufgabe des Remote Operators. Umso wichtiger ist die Entwicklung eines geeigneten HMI für die Teleoperation von hochautomatisierten Fahrzeugen. Die Recherche dieser Arbeit zu diesem Thema zeigt verschiedene Lücken auf, die eine Entwicklung solcher HMI erschweren. Insbesondere die Effekte von Monitoren oder Head-Mounted-Displays, der Videoqualität oder zusätzlicher Sensormodalitäten weisen auf offene Fragestellungen hin. Das Ziel dieser Arbeit ist es somit, die identifizierten Lücken zu schließen, indem die Auswirkungen von verschiedenen Sensortypen und deren Darstellungsvarianten auf die Schlüsselkennzahlen der Teleoperation verstanden und daraus Empfehlungen für ein geeignetes HMI generiert werden. Hierzu werden auf Grundlage des ermittelten Stands der Technik und den Zielen der Arbeit die relevanten Forschungsfragen abgeleitet.

Die erste Frage (F1) zielt auf das geeignete Anzeigekonzept für die direkte Steuerung von automatisierten Fahrzeugen ab. Hierbei werden drei Unterfragen formuliert: (F1A) Welche visuellen Darstellungsformen und Anzeigegeräte sind geeignet, um ein angemessenes Level an Situationsbewusstsein zu erreichen? (F1B) Wie beeinflusst die Qualität der Kameradaten das Situationsbewusstsein der Benutzer des Systems? (F1C) Und wie können die Informationen aus Kamera- und LiDAR-Sensoren kombiniert werden, um die Tiefenwahrnehmung der Remote-Operatoren zu verbessern?

Die zweite Forschungsfrage (F2) befasst sich mit der Auswirkung einer zunehmenden Systemerfahrung auf die Mensch-Maschine-Interaktion hinsichtlich der Entwicklung des Situationsbewusstseins, der Immersion, der Telepräsenz und der Gebrauchstauglichkeit.

Um diese Forschungsfragen zu beantworten, wird das Vorgehen nach der ISO-Norm gewählt. Der Startpunkt ist die Evaluierung des bereits existierenden Systems im Rahmen einer Vorstudie. Auf der Grundlage der Vorstudie, des ermittelten Standes der Technik und der formulierten Forschungsfragen werden verschiedene HMI-Varianten entwickelt. Diese ermöglichen die Beantwortung der Forschungsfragen im Rahmen von zwei Studien.

Die erste Studie untersucht die Fragen F1A, F1B und F2. F1A: Die Ergebnisse zeigen, dass sowohl die Darstellungsform als auch die Anzeigegeräte keinen signifikanten Einfluss auf das Situationsbewusstsein oder andere messbare Faktoren während der Teleoperation haben. Die Probanden konnten mit jeder HMI-Variante ein gleich hohes Situationsbewusstsein erreichen. In Anbetracht des Unterschieds zwischen den HMI-Varianten ist dies nur auf die Abstraktionsfähigkeit der Probanden zurückzuführen. F1B: Im Rahmen der untersuchten Qualitätstufen gab es einen schwach negativen Effekt der niedrigen Qualität auf die Immersion, den Workload, die Spurschätzung und die Vorhersagegenauigkeit, jedoch nicht auf die erkannten Verkehrsteilnehmer, Verkehrsschilder oder die geschätzte Geschwindigkeit. Folglich ist der Einfluss der Videoqualität geringer als angenommen, und Probanden können auch mit einer schlechten Qualität die notwendigen Verkehrsteilnehmer und -elemente wahrnehmen. Die Nutzungsdauer des Systems hat von allen unabhängigen Variablen den größten Effekt auf die untersuchten abhängigen Variablen. Vor allem bei den subjektiven Faktoren Workload, Usability und Sicherheitsempfinden ist ein signifikant positiver Effekt über die Nutzungsdauer feststellbar. Aber auch bei den erkannten Verkehrsteilnehmern und Verkehrsschildern tritt ein positiver Effekt auf. Auch wenn die gemessenen unabhängigen Variablen keinen signifikanten Unterschied zwischen den HMI aufweisen, zeigt der direkte Vergleich zwischen den HMI eine deutliche Präferenz der Probanden für das in dieser Arbeit entwickelte Head-Mounted-Display-HMI. So bevorzugen sowohl für die aufgezeichneten Szenen als auch für die reale teleoperierte Fahrt mit dem Versuchsträger mehr als zwei Drittel der Probanden das Head-Mounted-Display-HMI (Abbildung 8.1) gegenüber den anderen HMI.



Abbildung 8.1: Entwickeltes HMI für die Teleoperation von hochautomatisierten Fahrzeugen

Die zweite Studie untersucht die Frage F1C: Wie können die Informationen aus Kamera- und LiDAR-Sensoren kombiniert werden, um die Tiefenwahrnehmung der Remote Operator zu verbessern? Die Ergebnisse zeigen, dass LiDAR-Daten keinen Effekt gegenüber Top-Down-Kameras in der präzisen Steuerung des Fahrzeugs mit nahen Hindernissen haben. Dennoch haben Probanden mit dem in dieser Arbeit entwickelten HMI gegenüber dem Referenz-HMI aufgrund der Top-Down-Kameras deutlich weniger Kollisionen mit den Hindernissen verursacht und konnten die Abstände besser einschätzen.

Auf Basis dieser Ergebnisse werden Empfehlungen für ein HMI für die Teleoperation von hochautomatisierten Fahrzeugen formuliert. Zusammenfassend sollte ein Head-Mounted-Display mit einer dreidimensionalen Projektion der Kameradaten für das Remote-Driving von hochautomatisierten Fahrzeugen verwendet werden (Abbildung 8.1).

Ist aufgrund äußerer Einschränkungen die Verwendung eines Head-Mounted-Displays nicht möglich, können alternativ konventionelle Monitore ohne Projektion verwendet werden. Wichtiger als die Art der Darstellung der Daten ist der Inhalt an sich. So hat die Anzeige von z. B. LiDAR-Daten keine Vorteile gegenüber der Anzeige von Nahbereichskameras. Weiterhin sollte eine möglichst hohe Qualität der Videodaten gewählt werden; kurzzeitige Qualitätsunterschiede können durch den Remote Operator jedoch kompensiert werden. Den größten potenziellen Effekt auf die Teleoperation hat die Trainings- bzw. Nutzungsdauer des Remote Operators mit dem System. Insbesondere hier sollte bei der Entwicklung des Systems Wert auf die Entwicklung eines Trainingsprogramms gelegt werden.



# Abbildungsverzeichnis

Abbildung 1.1:	Übersicht über den Aufbau der Arbeit .....	4
Abbildung 2.1:	Angenäherte Übereinstimmung zwischen SAE, BAST und NHTSA nach [29, S. 32] .....	6
Abbildung 2.2:	Taxonomie für Remote Human Input Systems nach Bogdoll et al. [32, S. 9]	7
Abbildung 2.3:	Links: Meilen Pro Disengagement für die Top-10 AV Firmen. Rechts: Entwicklung der Meilen pro Disengagement von 2015 bis 2022.....	7
Abbildung 2.4:	Sense-Plan-Act: Architekturübersicht nach Biggs [43] .....	8
Abbildung 2.5:	Radar- und Kameradatenvisualisierung realer Szenen nach Schuhmann et al. [49, S. 4] .....	9
Abbildung 2.6:	Sensordatenausschnitt Ouster LiDAR OS1 [57] .....	11
Abbildung 2.7:	Übersicht unterschiedlicher Sensortypen in Hinblick auf Reichweite, menschliche Interpretierbarkeit und vorhandene Tiefeninformationen .....	12
Abbildung 2.8:	Sensorsetup verschiedener HAF. Links: Waymo [9]. Rechts: NuTonomy [64, S. 4]. .....	13
Abbildung 2.9:	Links: Symbiose zwischen Teleoperation und HAF nach Tiwari [78]. Rechts: Anzahl der veröffentlichten Teleoperationspatente nach Majstorovic et al. [34]. .....	13
Abbildung 2.10:	Kumulative Verteilungsfunktion (CDF) der erfassten Bandbreite während einer vierstündigen Messfahrt in München .....	15
Abbildung 2.11:	Übersicht über die verschiedenen Steuerungsarten und Interaktionsmechanismen. Links: Robotik [126, S. 781]. Mitte: Einordnung nach SAE [28, S. 18] und Bogdoll [32, S. 9]. Rechts: Interaktionsmechanismen in der Militärtechnik nach Weil et al. [127, S. 9]. .....	16
Abbildung 2.12:	Übersicht verschiedener HMI für die Teleoperation von HAF. Links: Einride [151]. Mitte: Bout et al. [152]. Rechts: Phantom Auto [153]. .....	17
Abbildung 2.13:	Übersicht verschiedener Hilfselemente. Links: Prädizierte Fahrzeug und Fahrradposition nach Chucholowski [187, S. 70]. Mitte: Dreidimensionale Berechnung der Fahrspur auf Basis von LiDAR-Daten und Geschwindigkeitsanzeige nach Ruiken et al. [188]. Rechts: 3-D HMI mit überlagerten LiDAR-Daten und Karte nach Yanco et al. [95]. .....	21
Abbildung 2.14:	Dreistufenmodell des Situationsbewusstseins nach Endsley [199, S. 98].	22
Abbildung 4.1:	Gestaltungsprozess nach DIN EN ISO 9241-210 [218, S. 9] .....	31
Abbildung 4.2:	Darstellung des Vorgehens dieser Arbeit anhand des Gestaltungsprozesses nach DIN EN ISO 9241-210 und Zuordnung der Forschungsfragen	32
Abbildung 5.1:	Sensorlayout Audi Q7. Links: Vogelperspektive. Rechts: Seitenansicht. ..	36
Abbildung 5.2:	Bildschirmaufnahme des Monitor-HMI inklusive LiDAR-Daten Visualisierung [171, S. 23] .....	36

Abbildung 5.3:	Links: Fehlender Übergang zwischen vorderer und linker Kamera [171, S. 28]. Mitte: Verbessertes Übergang. Rechts: Vollständige Ansicht, dargestellt mit LiDAR-Daten als blaue Blöcke und Hilfselementen für die Fahrspur. ....	37
Abbildung 5.4:	Von links nach rechts: Fotos der verwendeten HMI [121, S. 14] und des Versuchsfahrzeugs an Station 3 und 4 sowie schematische Darstellung der Teststrecke .....	37
Abbildung 5.5:	Erweitertes Sensorlayout des Audi Q7, ergänzt um Weitwinkelkameras und Velodyne Puck. Links: Vogelperspektive. Rechts: Seitenansicht.....	42
Abbildung 5.6:	Softwarearchitektur des implementierten HMI und verschiedener Komponenten, adaptiert nach [249].....	42
Abbildung 5.7:	Grundlagen der Computergrafik. Links: Modellierung. Mitte: Textur. Rechts: Transformation und Rendering.....	43
Abbildung 5.8:	Links: Anordnung mehrerer Videostreams zur orthogonalen Projektion. Mitte: Anordnung nach Hosseini [164]. Rechts: 360° Anordnung. ....	44
Abbildung 5.9:	Mögliche geometrische Formen zur dreidimensionalen Darstellung der Kameradaten. Von links nach rechts: A: Kugel, B: Halbkugel und Scheibe, C: Offener Quader mit seitlich gerundeten Kanten, D: Geschlossener Quader mit gerundeten Kanten .....	45
Abbildung 5.10:	Berechnung der UV-Koordinaten mit vorvernetzten Geometrien. Links: Kamerasichtbereich. Rechts: Ergebnis der 3-D nach 2-D Projektion in das Kamerakoordinatensystem.....	45
Abbildung 5.11:	Berechnung der UV-Koordinaten mit vorvernetzten Geometrien. Links: Kamerasichtbereich. Rechts: Ergebnis der 3-D nach 2-D Projektion in das Kamerakoordinatensystem.....	46
Abbildung 5.12:	Ergebnis der vorgestellten Methode für die Frontkamera.....	47
Abbildung 5.13:	Transparenzfunktion $\alpha(u, v)$ .....	47
Abbildung 5.14:	Ergebnis der 3-D-Videodatenvisualisierung auf einem Monitor.....	48
Abbildung 5.15:	Ergebnis der 3-D-Visualisierung innerhalb eines HMD für das linke und rechte Auge.....	48
Abbildung 5.16:	Visualisierung der LiDAR-Daten als Marker innerhalb des 3-D HMI. Zur Verbesserung der Sichtbarkeit um das Fahrzeug werden Chassisteile ausgeblendet. ....	50
Abbildung 5.17:	Oben: Auf Basis der LiDAR-Daten vernetztes Vertex-Mesh. Unten: Auf das Mesh projizierte Kameradaten. [260].....	51
Abbildung 5.18:	Links: Unvernetzte Rohdaten des Velodyne LiDAR-Sensors. Rechts: Vernetzte Geometrie auf Basis der LiDAR-Daten. [262] .....	52
Abbildung 5.19:	Links: 2-D-Kamerabild. Rechts: Fusion der Kamera- und LiDAR-Daten. [262]	52
Abbildung 6.1:	Oben links: Operator-Arbeitsplatz. Oben rechts: Monitor 2-D. Unten links: Monitor 3-D. Unten rechts: HMD. ....	55
Abbildung 6.2:	Versuchsablauf .....	57
Abbildung 6.3:	Jitterplot und Mittelwert der erkannten Verkehrsteilnehmer [%] über die drei Gruppen .....	61
Abbildung 6.4:	Jitterplot und Mittelwert der erkannten Verkehrsteilnehmer [%] über die Qualität hoch und niedrig .....	62
Abbildung 6.5:	Mittelwert und Perzentile der erkannten Verkehrsteilnehmer [%] über die vier Termine .....	62

Abbildung 6.6:	Jitterplot und Mittelwert der erkannten Verkehrsschilder [%] über die drei Gruppen .....	63
Abbildung 6.7:	Jitterplot und Mittelwert der erkannten Verkehrsschilder [%] über die drei Gruppen und die Qualität .....	64
Abbildung 6.8:	Jitterplot und Mittelwert der erkannten Verkehrsschilder [%] über die drei Gruppen und Termine.....	64
Abbildung 6.9:	Boxplot des Fehlers der Geschwindigkeitsschätzung über die drei Gruppen	65
Abbildung 6.10:	Boxplot des Fehlers der Geschwindigkeitsschätzung über die drei Gruppen und der Qualität .....	66
Abbildung 6.11:	Boxplot des Fehlers der Geschwindigkeitsschätzung über die vier Termine und drei Darstellungsformen.....	66
Abbildung 6.12:	Anteil richtiger Antworten in der Schätzung der Fahrspur über die Darstellungform .....	67
Abbildung 6.13:	Anteil richtiger Antworten in der Schätzung der Fahrspur über die Qualität	68
Abbildung 6.14:	Anteil richtiger Antworten in der Schätzung der Fahrspur über die Termine	68
Abbildung 6.15:	Anteil richtiger Antworten in der Vorhersage über die Gruppe .....	69
Abbildung 6.16:	Anteil richtiger Antworten in der Vorhersage über die Qualität .....	70
Abbildung 6.17:	Anteil richtiger Antworten in der Vorhersage über die Termine.....	70
Abbildung 6.18:	Usability über die drei Gruppen .....	71
Abbildung 6.19:	Usability über Qualität .....	72
Abbildung 6.20:	Usability über die Termine .....	72
Abbildung 6.21:	Workload über die drei Gruppen .....	73
Abbildung 6.22:	Workload über Qualität .....	74
Abbildung 6.23:	Workload über die einzelnen Termine und Gruppen .....	74
Abbildung 6.24:	Immersion über die drei Gruppen.....	75
Abbildung 6.25:	Immersion über Qualität.....	76
Abbildung 6.26:	Immersion über Termin .....	76
Abbildung 6.27:	Sicherheitsgefühl über die drei Gruppen.....	77
Abbildung 6.28:	Sicherheitsgefühl über Qualität.....	78
Abbildung 6.29:	Sicherheitsgefühl über die Termine .....	78
Abbildung 6.30:	Sicherheitsgefühl über Verkehrsaufkommen. Die Skala reicht von G: Gering (0-3 Verkehrsteilnehmer), über M: Mittel (4-7 Verkehrsteilnehmer), bis hin zu H: Hoch (8 oder mehr Verkehrsteilnehmer).....	79
Abbildung 6.31:	Links: Probandenkonstellation zu Beginn des Vergleichs und Wechsel zwischen den Gruppen. Rechts: Präferenz der Probanden nach dem Vergleich. [263] .....	79
Abbildung 6.32:	Links: Probandenkonstellation am Anfang des Vergleichs und Wechsel zwischen den Gruppen. Rechts: Präferenz der Probanden nach dem Vergleich. [263] .....	80
Abbildung 6.33:	HMI Übersicht. Blaue Flächen repräsentieren Kameradaten, während dunkelblaue Quader und rote Punkte LiDAR-Daten darstellen.....	87
Abbildung 6.34:	Links: Abstände zu seitlichen Hindernissen je Gruppe. Rechts: Absoluter Schätzfehler je Gruppe in [m]. .....	88
Abbildung 6.35:	Abstände zwischen zwei Hindernissen je Gruppe.....	89
Abbildung 6.36:	Abstände zur Haltelinie je Gruppe .....	90
Abbildung 6.37:	Links: Boxplots der Antworten des Abschlussfragebogens. Rechts: Boxplots des Workloads, gemessen mit dem NASA TLX Fragebogens [244].	90

Abbildung 8.1:	Entwickeltes HMI für die Teleoperation von hochautomatisierten Fahrzeugen.....	98
Abbildung A.1:	Residuen LMM Verkehrsteilnehmer .....	xxxvii
Abbildung A.2:	DHARMA Residual Analyse LMM Verkehrsteilnehmer .....	xxxviii
Abbildung A.3:	DHARMA Residual Analyse LMM Verkehrsschilder.....	xliv
Abbildung A.4:	Analyse der Verteilung.....	I
Abbildung A.5:	DHARMA Residual Analyse LMM Geschwindigkeit gm0 .....	li
Abbildung A.6:	DHARMA Residual Analyse LMM Spur .....	lvii
Abbildung A.7:	DHARMA Residual Analyse LMM Vorhersage .....	lxiii
Abbildung A.8:	Residuen LMM Usability .....	lxxi
Abbildung A.9:	DHARMA Residual Analyse LMM Usability .....	lxxii
Abbildung A.10:	DHARMA Residual Analyse LMM Workload .....	lxxvi
Abbildung A.11:	Residuen LMM Immersion.....	lxxxii
Abbildung A.12:	DHARMA Residual Analyse LMM Immersion.....	lxxxiii
Abbildung A.13:	DHARMA Residual Analyse LMM Verkehrsteilnehmer .....	lxxxix



# Tabellenverzeichnis

Tabelle 3.1:	Vergleichende Darstellung von Veröffentlichungen im Bereich der Teleoperation und Einordnung dieser Arbeit. (✓: Vorhanden, „-“: Nicht vorhanden, Mo.: Monitore, L.:Laptop, sim.: Simulation, LZ.:Langzeit ,S+R: Such und Rettung, Dediziert: Eine Kamera pro Monitor, SB.: Situationsbewusstsein)	28
Tabelle 5.1:	LiDAR Option .....	49
Tabelle 6.1:	Übersicht der Studienergebnisse inkl. Richtung der Änderung (hoch: positiv, runter: negativ) und einzelnen Faktoren ( „-“ nicht signifikant, $\Delta$ $\nabla$ Tendenz $p < 0.1$ , $\blacktriangle$ $\blacktriangledown$ signifikant $p < 0.05$ , $\blacktriangle\blacktriangle$ $\blacktriangledown\blacktriangledown$ signifikant $p < 0.01$ ) .....	81



# Literaturverzeichnis

- [1] “Dunarea de Jos” University of Galati, M. A. Potirniche, G. F. Capatana und “Dunarea de Jos” University of Galati, „STUDY OF THE BEHAVIOUR FOR THE WORK EQUIPMENT OF A FORKLIFT DURING THE WORKING PROCESS USING FINITE ELEMENT ANALYSIS,“ *International Journal of Modern Manufacturing Technologies*, Bd. 14, Rn. 3, S. 219–226, 2022, DOI: 10.54684/ijmmt.2022.14.3.219.
- [2] E. Brynjolfsson und A. McAfee, *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*, First published as a Norton paperback, New York London, W. W. Norton & Company, 2016, ISBN: 978-0-393-35064-7.
- [3] J. Danaher, *Automation and Utopia: Human Flourishing in a World without Work*, Cambridge (Mass.), Harvard university press, 2019, ISBN: 978-0-674-98424-0.
- [4] J. Voelcker. „Autonomous Vehicles Complete DARPA Urban Challenge,“ 2023. [Online]. Verfügbar: <https://spectrum.ieee.org/autonomous-vehicles-complete-darpa-urban-challenge> [aufgerufen am 02. 02. 2023].
- [5] „Mercedes Becomes the First Automaker to Sell Level 3 Self-Driving Vehicles in California,“ 2023. [Online]. Verfügbar: <https://www.engadget.com/mercedes-becomes-the-first-automaker-to-sell-level-3-self-driving-vehicles-in-california-103504319.html> [aufgerufen am 16. 07. 2023].
- [6] „Ab Frühjahr: Hochautomatisiertes Fahren auf Level 3 im neuen BMW 7er.“ 2024. [Online]. Verfügbar: <https://www.press.bmwgroup.com/deutschland/article/detail/T0438214DE/ab-fruehjahr:-hochautomatisiertes-fahren-auf-level-3-im-neuen-bmw-7er?language=de> [aufgerufen am 21. 01. 2024].
- [7] „. Zoox: How Zoox Uses TeleGuidance to Provide Remote Assistance to Its Autonomous Vehicles,“ 2020. Verfügbar: <https://www.youtube.com/watch?v=%20NKQHuuTvx78> [aufgerufen am 11. 01. 2023].
- [8] S. Smith, „Apple’s Californian Autonomous Car Program Is Larger Than Both Tesla’s And Mercedes’ Efforts,“ 2023. Verfügbar: <https://www.carscoops.com/2023/03/apples-californian-autonomous-car-program-is-larger-than-both-teslas-and-mercedess-efforts/>.
- [9] Waymo. „How Our Cars Drive - Waymo One Help,“ 2023. [Online]. Verfügbar: <https://support.google.com/waymo/answer/9190838?hl=en> [aufgerufen am 14. 02. 2023].
- [10] F. Hauer, T. Schmidt, B. Holzmueller und A. Pretschner, „Did We Test All Scenarios for Automated and Autonomous Driving Systems?,“ in *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, 2019, S. 2950–2955, ISBN: 978-1-5386-7024-8. DOI: 10.1109/ITSC.2019.8917326.
- [11] „Driverless Robotaxis Are Now Available for Public Rides in China,“ 2023. [Online]. Verfügbar: <https://www.engadget.com/autox-fully-driverless-robotaxi-china-145126521.html> [aufgerufen am 16. 07. 2023].

- [12] „Waymo to Start Driverless Ride Sharing in Phoenix Area This Year,“ 2023. [Online]. Verfügbar: <https://eu.azcentral.com/story/money/business/tech/2018/01/30/waymo-start-driverless-ride-sharing-phoenix-area-year/1078466001/> [aufgerufen am 16. 07. 2023].
- [13] C. Said. „Cruise Deploys True Robot Cars in S.F. — No Backup Drivers behind Wheel,“ 2023. [Online]. Verfügbar: <https://www.sfchronicle.com/business/article/Cruise-deploys-true-robot-cars-in-S-F-no-15788555.php> [aufgerufen am 16. 07. 2023].
- [14] „Self-Driving Car Blocks Police Responding to San Francisco Shooting,“ 2023. [Online]. Verfügbar: <https://www.ktvu.com/news/self-driving-car-blocks-police-responding-to-san-francisco-shooting> [aufgerufen am 16. 07. 2023].
- [15] „Waymo Car Blocks Traffic near SF Parade,“ 2023. [Online]. Verfügbar: [https://news.yahoo.com/waymo-car-blocks-traffic-near-160400750.html?guccounter=1&guce\\_referrer=aHR0cHM6Ly93d3cuZ29vZ2xlLmNvbS8&guce\\_referrer\\_sig=AQAAAEbBkC2BwadGXzRttxYlaU\\_sN\\_las9H1LmvuXSGos8ydZ8tMbyFgm-\\_TTP4s0YLoF8DPuzpk4IVuerh1k0fz6yZgJkffVoXNqH3SjCXqwmn\\_lokTvAnFZEi2Dxbun-q2Fr7oM6e7poecQovCR1kRHrRSfXrXP0J5Up4w3fBhs6fy](https://news.yahoo.com/waymo-car-blocks-traffic-near-160400750.html?guccounter=1&guce_referrer=aHR0cHM6Ly93d3cuZ29vZ2xlLmNvbS8&guce_referrer_sig=AQAAAEbBkC2BwadGXzRttxYlaU_sN_las9H1LmvuXSGos8ydZ8tMbyFgm-_TTP4s0YLoF8DPuzpk4IVuerh1k0fz6yZgJkffVoXNqH3SjCXqwmn_lokTvAnFZEi2Dxbun-q2Fr7oM6e7poecQovCR1kRHrRSfXrXP0J5Up4w3fBhs6fy) [aufgerufen am 16. 07. 2023].
- [16] „Waymo CEO: Autonomous Cars Won’t Ever Be Able to Drive in All Conditions,“ 2023. [Online]. Verfügbar: <https://www.cnet.com/roadshow/news/alphabet-google-waymo-ceo-john-krafcik-autonomous-cars-wont-ever-be-able-to-drive-in-all-conditions/> [aufgerufen am 16. 07. 2023].
- [17] G. Niemeyer, C. Preusche und G. Hirzinger, „Telerobotics,“ in *Springer Handbook of Robotics*, B. Siciliano und O. Khatib, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, S. 741–757, ISBN: 978-3-540-23957-4 978-3-540-30301-5. DOI: 10.1007/978-3-540-30301-5\_32.
- [18] A. Podhurst. „Council Post: Teleoperation: The “Picks And Shovels” Of The Autonomous Vehicle Gold Rush,“ 2023. [Online]. Verfügbar: <https://www.forbes.com/sites/forbestechcouncil/2021/08/03/teleoperation-the-picks-and-shovels-of-the-autonomous-vehicle-gold-rush/> [aufgerufen am 16. 07. 2023].
- [19] O. Skorka, „Toward a Digital Camera to Rival the Human Eye,“ *Journal of Electronic Imaging*, Bd. 20, Rn. 3, S. 033009, 2011, DOI: 10.1117/1.3611015.
- [20] J. Contributor. „Japan BrandVoice: Telexistence: How This Tokyo Startup Is Building Real-Life Avatar Robots,“ 2023. [Online]. Verfügbar: <https://www.forbes.com/sites/japan/2018/01/26/telexistence-how-this-tokyo-startup-is-building-real-life-avatar-robots/> [aufgerufen am 16. 07. 2023].
- [21] S. Shao, Q. Zhou und Z. Liu, „Mental Workload Characteristics of Manipulator Teleoperators with Different Spatial Cognitive Abilities,“ *International Journal of Advanced Robotic Systems*, Bd. 16, Rn. 6, S. 172988141988804, 2019, DOI: 10.1177/1729881419888042.
- [22] D. Drascic, „Skill Acquisition and Task Performance in Teleoperation Using Monoscopic and Stereoscopic Video Remote Viewing,“ *Proceedings of the Human Factors Society Annual Meeting*, Bd. 35, Rn. 19, S. 1367–1371, 1991, DOI: 10.1177/154193129103501906.
- [23] „Phantom Auto Will Tour City,“ *Milwaukee Sentinel*, 1926. Verfügbar: <https://web.archive.org/web/20181010202440/https://news.google.com/newspapers?id=unBQAAAAIBAJ&sjid=QQ8EAAAAIBAJ&pg=7304,3766749> [aufgerufen am 23. 07. 2023].

- [24] „Audi TTS Pikes Peak (Technikträger) (2009),“ 2023. [Online]. Verfügbar: <https://www.audi-mediacenter.com:443/de/audi-tts-pikes-peak-techniktraeger-188> [aufgerufen am 23.07.2023].
- [25] S. Tibken. „Waymo CEO: Autonomous Cars Won't Ever Be Able to Drive in All Conditions,“ 2021. [Online]. Verfügbar: <https://www.cnet.com/news/alphabet-google-waymo-ceo-john-krafcik-autonomous-cars-wont-ever-be-able-to-drive-in-all-conditions/> [aufgerufen am 07.01.2021].
- [26] *Rechtsfolgen zunehmender Fahrzeugautomatisierung: gemeinsamer Schlussbericht der Projektgruppe*, (Berichte der Bundesanstalt für Strassenwesen. F, Fahrzeugtechnik), Bremerhaven, Wirtschaftsverlag NW, 2012, ISBN: 978-3-86918-189-9.
- [27] H.-T. Ebner. „Motivation und Handlungsbedarf für Automatisiertes Fahren“,“ DVR-Kolloquium Automatisiertes Fahren (Bonn). 11. Dez. 2013.
- [28] SAE. „*Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles*,“ Apr. 2021.
- [29] *Automated Driving: Safer and More Efficient Future Driving*, Cham, Springer International Publishing, 2017, ISBN: 978-3-319-31893-6 978-3-319-31895-0. DOI: 10.1007/978-3-319-31895-0.
- [30] SAE und O.-R. A. D. ( committee, „Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems,“ SAE International, 01.2014, DOI: 10.4271/J3016\_201401.
- [31] E. Juliussen. „AVs Will Need Teleoperation: Here's Why,“ 2023. [Online]. Verfügbar: <https://www.eetimes.com/avs-will-need-teleoperation-heres-why/> [aufgerufen am 23.07.2023].
- [32] D. Bogdoll, S. Orf, L. Töttel und J. M. Zöllner, „Taxonomy and Survey on Remote Human Input Systems for Driving Automation Systems,“ in *Advances in Information and Communication*. Bd. 439, K. Arai, Hrsg. Cham: Springer International Publishing, 2022, S. 94–108, ISBN: 978-3-030-98014-6 978-3-030-98015-3. DOI: 10.1007/978-3-030-98015-3\_6.
- [33] M. Herger. „2022 Disengagement Reports aus Kalifornien,“ 2024. [Online]. Verfügbar: <https://derletztefuehrerscheinuling.com/2023/02/18/2022-disengagement-reports-aus-kalifornien/> [aufgerufen am 21.01.2024].
- [34] D. Majstorovic, S. Hoffmann, F. Pfab, A. Schimpe, M.-M. Wolf et al. „Survey on Teleoperation Concepts for Automated Vehicles,“ 2023. [Online]. Verfügbar: <http://arxiv.org/abs/2208.08876> [aufgerufen am 13.01.2023].
- [35] J. Kocić, N. Jovičić und V. Drndarević, „An End-to-End Deep Neural Network for Autonomous Driving Designed for Embedded Automotive Platforms,“ *Sensors*, Bd. 19, Rn. 9, S. 2064, 2019, DOI: 10.3390/s19092064.
- [36] Y. Pan, C.-A. Cheng, K. Saigol, K. Lee, X. Yan et al., „Agile Autonomous Driving Using End-to-End Deep Imitation Learning,“ 2017, DOI: 10.48550/ARXIV.1709.07174.
- [37] Y. Xiao, F. Codevilla, A. Gurram, O. Urfalioglu und A. M. López, „Multimodal End-to-End Autonomous Driving,“ 2019, DOI: 10.48550/ARXIV.1906.03199.
- [38] H. Xu, Y. Gao, F. Yu und T. Darrell, „End-to-End Learning of Driving Models from Large-scale Video Datasets,“ 2016, DOI: 10.48550/ARXIV.1612.01079.

- [39] M. Bojarski, D. Del Testa, D. Dworakowski, B. Firner, B. Flepp et al., „End to End Learning for Self-Driving Cars,“ 2016, DOI: 10.48550/ARXIV.1604.07316.
- [40] O. S. Tas, F. Kuhnt, J. M. Zollner und C. Stiller, „Functional System Architectures towards Fully Automated Driving,“ in *2016 IEEE Intelligent Vehicles Symposium (IV)*, 2016, S. 304–309, ISBN: 978-1-5090-1821-5. DOI: 10.1109/IVS.2016.7535402.
- [41] A. Srivastava, „Sense-Plan-Act in Robotic Applications,“ 2019, DOI: 10.13140/RG.2.2.21308.36481.
- [42] S. Liu, L. Li, X. Motors, J. Tang, S. Wu et al., *Creating Autonomous Vehicle Systems, Second Edition*, 2. Aufl., Morgan & Claypool publishers, 2020, ISBN: 978-1-68173-935-9.
- [43] G. Biggs. „Overview · Wiki · Autoware Foundation \_ MovedToGitHub \_ Autoware · GitLab.Pdf,“ 2023. [Online]. Verfügbar: <https://gitlab.com/autowarefoundation/autoware.ai/autoware/-/wikis/Overview> [aufgerufen am 03. 02. 2023].
- [44] H. A. Ignatious, H.-E. Sayed und M. Khan, „An Overview of Sensors in Autonomous Vehicles,“ *Procedia Computer Science*, Bd. 198, S. 736–741, 2022, DOI: 10.1016/j.procs.2021.12.315.
- [45] J. Vargas, S. Alsweiss, O. Toker, R. Razdan und J. Santos, „An Overview of Autonomous Vehicles Sensors and Their Vulnerability to Weather Conditions,“ *Sensors*, Bd. 21, Rn. 16, S. 5397, 2021, DOI: 10.3390/s21165397.
- [46] H. Winner, S. Hakuli und G. Wolf, *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort ; mit 45 Tabellen*, (Praxis ATZ-MTZ Fachbuch), 1. Aufl, Wiesbaden, Vieweg + Teubner, 2009, ISBN: 978-3-8348-0287-3.
- [47] D. Freundt und B. Lucas, „Long Range Radar Sensor for High-Volume Driver Assistance Systems Market,“ 2008, S. 2008-01–0921, DOI: 10.4271/2008-01-0921.
- [48] „Continental Automotive,“ 2023. [Online]. Verfügbar: <http://www.continental-automotive.com/DE/Passenger-Cars/Autonomous-Mobility/Enablers/Radars/SRR600> [aufgerufen am 23. 07. 2023].
- [49] O. Schumann, M. Hahn, N. Scheiner, F. Weishaupt, J. F. Tilly et al. „RadarScenes: A Real-World Radar Point Cloud Data Set for Automotive Applications,“ 2023. [Online]. Verfügbar: <http://arxiv.org/abs/2104.02493> [aufgerufen am 07. 02. 2023].
- [50] H. Kuttruff, „Ultraschall,“ in *Taschenbuch der Technischen Akustik*, G. Müller und M. Möser, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004, S. 751–765, ISBN: 978-3-642-62343-1 978-3-642-18893-0. DOI: 10.1007/978-3-642-18893-0\_22.
- [51] F. Ng, „Ultrasonic Sensors,“ 2020, DOI: 10.13140/RG.2.2.33638.78404.
- [52] L. Zhu, „Analyze the Advantages and Disadvantages of Different Sensors for Autonomous Vehicles:“ in *2022 7th International Conference on Social Sciences and Economic Development (ICSSSED 2022)*, 2022, DOI: 10.2991/aebmr.k.220405.171.
- [53] A. Academy, „The 2019 Audi A8 Driver Assistance Systems,“ 20.06.2018. pmid: 2019. Verfügbar: <https://static.nhtsa.gov/odi/tsbs/2018/MC-10144686-9999.pdf> [aufgerufen am 23. 07. 2023].
- [54] A. Krizhevsky, I. Sutskever und G. E. Hinton, „ImageNet Classification with Deep Convolutional Neural Networks,“ in *Advances in Neural Information Processing Systems*, 2012. Verfügbar: [https://papers.nips.cc/paper\\_files/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html](https://papers.nips.cc/paper_files/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html) [aufgerufen am 23. 07. 2023].

- [55] S. Grigorescu, B. Trasnea, T. Cocias und G. Macesanu, „A Survey of Deep Learning Techniques for Autonomous Driving,“ *Journal of Field Robotics*, Bd. 37, Rn. 3, S. 362–386, 2020, DOI: 10.1002/rob.21918. arXiv: 1910.07738 [cs].
- [56] H. Jang, Y. Ko, Y. Lee und M. Jeon. „Light Robust Monocular Depth Estimation For Outdoor Environment Via Monochrome And Color Camera Fusion,“ 2023. [Online]. Verfügbar: <http://arxiv.org/abs/2202.12108> [aufgerufen am 23. 07. 2023].
- [57] Ouster. „OS0 Ultra-wide Field-of-View Lidar Sensor for Autonomous Vehicles and Robotics,“ 2023. [Online]. Verfügbar: <https://ouster.com/products/scanning-lidar/os0-sensor/> [aufgerufen am 07. 02. 2023].
- [58] Velodyne. „*Velodyne Lidar - ULTRA Puck*,“ 2019. Verfügbar: <https://velodynelidar.com/products/ultra-puck/> [aufgerufen am 02. 07. 2023].
- [59] Z. Liu, M. Arief und D. Zhao, „Where Should We Place LiDARs on the Autonomous Vehicle? - An Optimal Design Approach,“ in *2019 International Conference on Robotics and Automation (ICRA)*, 2019, S. 2793–2799, ISBN: 978-1-5386-6027-0. DOI: 10.1109/ICRA.2019.8793619.
- [60] P. P. J. Feig, „Klassifizierung des Beschädigungsrisikos unter dem Einfluss von Fahrerassistenzsystemen,“ Technische Universität München, Garching, 2019.
- [61] S. Kruzic, J. Music und I. Stancic, „Influence of Human-Computer Interface Elements on Performance of Teleoperated Mobile Robot,“ in *2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 2017, S. 1015–1020, ISBN: 978-953-233-090-8. DOI: 10.23919/MIPRO.2017.7973573.
- [62] Zehang Sun, G. Bebis und R. Miller, „On-Road Vehicle Detection: A Review,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Bd. 28, Rn. 5, S. 694–711, 2006, DOI: 10.1109/TPAMI.2006.104.
- [63] „*ISO 26262-1 Road Vehicles - Functional Safety*,“ Version 1. Switzerland, 15. Nov. 2011.
- [64] H. Caesar, V. Bankiti, A. H. Lang, S. Vora, V. E. Liong et al. „nuScenes: A Multimodal Dataset for Autonomous Driving,“ 2023. [Online]. Verfügbar: <http://arxiv.org/abs/1903.11027> [aufgerufen am 23. 07. 2023].
- [65] C. Mutzenich, S. Durant, S. Helman und P. Dalton, „Updating Our Understanding of Situation Awareness in Relation to Remote Operators of Autonomous Vehicles,“ *Cognitive Research: Principles and Implications*, Bd. 6, Rn. 1, S. 9, 2021, DOI: 10.1186/s41235-021-00271-8.
- [66] C. Kettwich, A. Schrank und M. Oehl, „Teleoperation of Highly Automated Vehicles in Public Transport: User-Centered Design of a Human-Machine Interface for Remote-Operation and Its Expert Usability Evaluation,“ *Multimodal Technologies and Interaction*, Bd. 5, Rn. 5, S. 26, 2021, DOI: 10.3390/mti5050026.
- [67] O. M. J. Carsten und HF-IRADS, „Human Factors Challenges of Remote Support and Control A Position Paper from HF-IRADS1 1. Introduction,“ 2020. Verfügbar: <https://api.semanticscholar.org/CorpusID:221999246>.
- [68] „Valeo Drive4U® Remote: World Premiere Test Track Demonstration at CES,“ 2023. [Online]. Verfügbar: <https://www.valeo.com/en/valeo-drive4u-remote-world-premiere-test-track-demonstration-at-ces/> [aufgerufen am 11. 01. 2023].
- [69] „Teleassist: How Humans Collaborate with the Aurora Driver,“ 2023. [Online]. Verfügbar: <https://blog.aurora.tech/engineering/teleassist-how-humans-collaborate-with-the-aurora> [aufgerufen am 11. 01. 2023].

- [70] „Nissan: Seamless Autonomous Mobility (SAM): The Ultimate Nissan Intelligent Integration,“ 2023. [Online]. Verfügbar: <https://global.nissannews.com/en/releases/seamless-autonomous-mobility-sam-the-ultimate-nissan-intelligent-integration> [aufgerufen am 11. 01. 2023].
- [71] Einride. „Einride Showcases One Operator, Multiple Vehicle Capability at a Customer Site,“ 2023. [Online]. Verfügbar: <https://www.einride.tech/press/einride-showcases-one-operator-multiple-vehicle-customer-site/> [aufgerufen am 01. 12. 2023].
- [72] Baidu. „Building a Self-Driving Car That People Can Trust,“ 2023. [Online]. Verfügbar: <https://www.technologyreview.com/2020/12/16/1014672/building-a-self-driving-car-that-people-can-trust/> [aufgerufen am 12. 01. 2023].
- [73] E. Ackerman. „What Full Autonomy Means for the Waymo Driver For Self-Driving Vehicles, Full Autonomy Might Not Be Quite as Full as You Think,“ 2023. [Online]. Verfügbar: <https://spectrum.ieee.org/full-autonomy-waymo-driver> [aufgerufen am 11. 01. 2023].
- [74] M. Aitken und S. Smith, „Telecommunications Network For Vehicles,“ Patent 20190222986A1, Januar 11, 2022.
- [75] S. S. Chen, S. Ghorbanian-Matloob, B. J. Goldman und M. G. Huang, „Context-Based Remote Autonomous Vehicle Assistance,“ Patent 20200272949A1.
- [76] A. Gerald, R. B. GmbH, K. Eckert und J. Schwarzmann, „System for Safe Teleoperated Travel,“ Deutschland Patent WO2020200535A1.
- [77] „Developing a Self-Driving System You Can Trust,“ 2023. [Online]. Verfügbar: <https://www.argo.ai/wp-content/uploads/2021/04/ArgoSafetyReport.pdf> [aufgerufen am 11. 01. 2023].
- [78] K. Tiwari. „Driving Complexity and Speed: The Puzzle-Piece Synchronicity Between Tele-Operation and Autonomy,“ 2023. [Online]. Verfügbar: <https://www.thedrive.com/tech/28895/driving-complexity-and-speed-the-puzzle-piece-synchronicity-between-tele-operation-and-autonomy> [aufgerufen am 01. 08. 2023].
- [79] R. C. Hampshire, S. Bao, W. S. Lasecki, A. Daw und J. Pender, „Beyond Safety Drivers: Applying Air Traffic Control Principles to Support the Deployment of Driverless Vehicles,“ *PLOS ONE*, Bd. 15, Rn. 5, e0232837, 2020, DOI: 10.1371/journal.pone.0232837.
- [80] „Fernride: Driving Logistics Automation,“ 2023. [Online]. Verfügbar: <https://www.fernride.com/> [aufgerufen am 01. 12. 2023].
- [81] „Ottopia - Safe and Cyber-Secure Teleoperation Software,“ 2023. [Online]. Verfügbar: <https://ottopia.tech/> [aufgerufen am 01. 12. 2023].
- [82] P. Auto. „Home — Phantom Auto - Enabling Autonomy Through Teleoperation,“ 2023. [Online]. Verfügbar: <https://phantom.auto/> [aufgerufen am 01. 12. 2023].
- [83] „Vay: A New Approach to Driverless Mobility,“ 2023. [Online]. Verfügbar: <https://www.tillmannbrothers.com/work/vay-a-new-approach-to-driverless-mobility> [aufgerufen am 01. 12. 2023].
- [84] M. Mihelj und J. Podobnik, *Haptics for Virtual Reality and Teleoperation*, (Intelligent Systems, Control and Automation: Science and Engineering). Bd. 64, Dordrecht, Springer Netherlands, 2012, ISBN: 978-94-007-5717-2 978-94-007-5718-9. DOI: 10.1007/978-94-007-5718-9.
- [85] A. Okamura, „Methods for Haptic Feedback in Teleoperated Robot-assisted Surgery,“ *Industrial Robot: An International Journal*, Bd. 31, Rn. 6, S. 499–508, 2004, DOI: 10.1108/01439910410566362.



- [86] P. F. Hokayem und M. W. Spong, „Bilateral Teleoperation: An Historical Survey,“ *Automatica*, Bd. 42, Rn. 12, S. 2035–2057, 2006, DOI: 10.1016/j.automatica.2006.06.027.
- [87] G. Clement, J. Vertut, R. Fournier, B. Espiau und G. Andre, „An Overview of CAT Control in Nuclear Services,“ in *Proceedings. 1985 IEEE International Conference on Robotics and Automation*, 1985, S. 713–718, DOI: 10.1109/ROBOT.1985.1087387.
- [88] Wang Wei und Yuan Kui, „Teleoperated Manipulator for Leak Detection of Sealed Radioactive Sources,“ in *IEEE International Conference on Robotics and Automation, 2004. Proceedings. ICRA '04. 2004*, 2004, 1682–1687 Vol.2, ISBN: 978-0-7803-8232-9. DOI: 10.1109/ROBOT.2004.1308066.
- [89] P. Appelqvist, J. Knuutila und J. Ahtiainen, „Development of an Unmanned Ground Vehicle for Task-Oriented Operation - Considerations on Teleoperation and Delay,“ in *2007 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, 2007, S. 1–6, ISBN: 978-1-4244-1263-1. DOI: 10.1109/AIM.2007.4412567.
- [90] P. Appelqvist, J. Knuutila und J. Ahtiainen, „Mechatronics Design of an Unmanned Ground Vehicle for Military Applications,“ in *Mechatronic Systems Applications*, A. M. D. Di Paola und G. Cicirelli, Hrsg. InTech, 2010, ISBN: 978-953-307-040-7. DOI: 10.5772/8919.
- [91] D. Yoerger, J. Newman und J.-J. Slotine, „Supervisory Control System for the JASON ROV,“ *IEEE Journal of Oceanic Engineering*, Bd. 11, Rn. 3, S. 392–400, 1986, DOI: 10.1109/JOE.1986.1145191.
- [92] J. Funda und R. Paul, „A Symbolic Teleoperator Interface For Time-delayed Underwater Robot Manipulation,“ in *OCEANS 91 Proceedings*, 1991, S. 1526–1533, ISBN: 978-0-7803-0202-0. DOI: 10.1109/OCEANS.1991.606520.
- [93] A. Madni, Yee-yeen Chu und A. Freedy, „Intelligent Interface For Remote Supervision And Control Of Underwater Manipulation,“ in *Proceedings OCEANS '83*, 1983, S. 106–110, DOI: 10.1109/OCEANS.1983.1152126.
- [94] M. Baker, R. Casey, B. Keyes und H. Yanco, „Improved Interfaces for Human-Robot Interaction in Urban Search and Rescue,“ in *2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No.04CH37583)*, 2004, S. 2960–2965, ISBN: 978-0-7803-8567-2. DOI: 10.1109/ICSMC.2004.1400783.
- [95] H. Yanco, M. Baker und J. L. Drury, „Analysis of Human-Robot Interaction for Urban Search and Rescue,“ 2006. Verfügbar: [https://www.academia.edu/2803958/Analysis\\_of\\_human\\_robot\\_interaction\\_for\\_urban\\_search\\_and\\_rescue](https://www.academia.edu/2803958/Analysis_of_human_robot_interaction_for_urban_search_and_rescue).
- [96] A. Valero, P. de la Puente und D. Rodríguez-Losada, „Exploratory Analysis of Operator:Robot Ratio in Search and Rescue Missions,“ *IFAC Proceedings Volumes*, Bd. 43, Rn. 23, S. 101–108, 2010, DOI: 10.3182/20101005-4-RO-2018.00034.
- [97] H. Martins, I. Oakley und R. Ventura, „Design and Evaluation of a Head-Mounted Display for Immersive 3D Teleoperation of Field Robots,“ *Robotica*, Bd. 33, Rn. 10, S. 2166–2185, 2015, DOI: 10.1017/S026357471400126X.
- [98] M. Mast, M. Španěl, G. Arbeiter, V. Štancl, Z. Materna et al., „Teleoperation of Domestic Service Robots: Effects of Global 3D Environment Maps in the User Interface on Operators' Cognitive and Performance Metrics,“ in *Social Robotics*. Bd. 8239, G. Herrmann, M. J. Pearson, A. Lenz, P. Bremner, A. Spiers et al., Hrsg. Cham: Springer International Publishing, 2013, S. 392–401, ISBN: 978-3-319-02674-9 978-3-319-02675-6. DOI: 10.1007/978-3-319-02675-6\_39.

- [99] C. L. Fernando, M. Furukawa, T. Kurogi, S. Kamuro, K. sato et al., „Design of TELESAR V for Transferring Bodily Consciousness in Telexistence,“ in *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2012, S. 5112–5118, ISBN: 978-1-4673-1736-8 978-1-4673-1737-5 978-1-4673-1735-1. DOI: 10.1109/IROS.2012.6385814.
- [100] M. Seeman, M. Broxvall und A. Saffiotti, „Virtual 360° Panorama for Remote Inspection,“ in *2007 IEEE International Workshop on Safety, Security and Rescue Robotics*, 2007, S. 1–5, ISBN: 978-1-4244-1568-7 978-1-4244-1569-4. DOI: 10.1109/SSRR.2007.4381282.
- [101] A. F. Winfield, „Future Directions in Teleoperated Robotics,“ *Intelligent Autonomous Systems Laboratory*, 2005. Verfügbar: <https://api.semanticscholar.org/CorpusID:9797959>.
- [102] B. Ross, J. Bares, D. Stager, L. Jackel und M. Perschbacher, „An Advanced Teleoperation Testbed,“ in *Field and Service Robotics*. Bd. 42, C. Laugier und R. Siegwart, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, S. 297–304, ISBN: 978-3-540-75403-9 978-3-540-75404-6. DOI: 10.1007/978-3-540-75404-6\_28.
- [103] A. Schimpe, S. Hoffmann und F. Diermeyer, „Adaptive Video Configuration and Bitrate Allocation for Teleoperated Vehicles,“ in *2021 IEEE Intelligent Vehicles Symposium (IV21)*, 2021, DOI: 10.48550/ARXIV.2102.10898.
- [104] S. Grange, T. Fong und C. Baur, „Effective Vehicle Teleoperation on the World Wide Web,“ in *Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation. Symposia Proceedings (Cat. No.00CH37065)*, 2000, S. 2007–2012, ISBN: 978-0-7803-5886-7. DOI: 10.1109/ROBOT.2000.844889.
- [105] S. Neumeier, E. A. Walelgne, V. Bajpai, J. Ott und C. Facchi, „Measuring the Feasibility of Teleoperated Driving in Mobile Networks,“ in *2019 Network Traffic Measurement and Analysis Conference (TMA)*, 2019, S. 113–120, ISBN: 978-3-903176-17-1. DOI: 10.23919/TMA.2019.8784466.
- [106] Silicon Valley Mobility und S. Beiker, „Unsettled Issues in Remote Operation for On-road Driving Automation,“ SAE International, 15.12.2021, DOI: 10.4271/EPR2021028.
- [107] A. Maskooki, G. Sabatino und N. Mitton, „Analysis and Performance Evaluation of the next Generation Wireless Networks,“ in *Modeling and Simulation of Computer Networks and Systems* Elsevier, 2015, S. 601–627, ISBN: 978-0-12-800887-4. DOI: 10.1016/B978-0-12-800887-4.00021-3.
- [108] J. Bienik, M. Uhrina, M. Vaculik und T. Mizdos, „Perceived Quality of Full HD Video - Subjective Quality Assessment,“ *Advances in Electrical and Electronic Engineering*, Bd. 14, Rn. 4, S. 437–444, 2016, DOI: 10.15598/aeer.v14i4.1831.
- [109] C. Yue, R. Jin, K. Suh, Y. Qin, B. Wang et al., „LinkForecast: Cellular Link Bandwidth Prediction in LTE Networks,“ *IEEE Transactions on Mobile Computing*, Bd. 17, Rn. 7, S. 1582–1594, 2018, DOI: 10.1109/TMC.2017.2756937.
- [110] D. McGovern. „*Experiences in Teleoperation of Land Vehicles*,“ Advanced Technology Division 5267, Sandia National Laboratories, 1987.
- [111] Y. Cai, „How Many Pixels Do We Need to See Things?,“ in *Computational Science — ICCS 2003*. Bd. 2659, P. M. A. Sloot, D. Abramson, A. V. Bogdanov, Y. E. Gorbachev, J. J. Dongarra et al., Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003, S. 1064–1073, ISBN: 978-3-540-40196-4 978-3-540-44863-1. DOI: 10.1007/3-540-44863-2\_105.

- [112] J.-M. Georg, J. Feiler, S. Hoffmann und F. Diermeyer, „Sensor and Actuator Latency during Teleoperation of Automated Vehicles,“ in *2020 IEEE Intelligent Vehicles Symposium (IV)*, 2020, S. 760–766, ISBN: 978-1-72816-673-5. DOI: 10.1109/IV47402.2020.9304802.
- [113] M. Gharba, A. R. Ali, V. Jain, S. Lapoehn, J.-M. Georg et al., „A Reconfigurable 5G Testbed for V2X and Industry 4.0 Applications,“ in *IEEE Globecom Workshop on 5G Test-Beds & Trials*, 2017, S. 5. Verfügbar: <https://elib.dlr.de/113143/>.
- [114] M. Schellmann, „5G als Triebkraft für vernetztes autonomes Fahren,“ *ZEVrail*, 2018. Verfügbar: <https://www.zevrail.de/artikel/5g-als-triebkraft-fuer-vernetztes-autonomes-fahren> [aufgerufen am 02. 10. 2023].
- [115] Proram Studi Teknik Informatika, Universitas Singaperbangsa Karawang, A. S. Tubagus, R. S. Mahdi, Proram Studi Teknik Informatika, Universitas Singaperbangsa Karawang, A. Rizal et al., „Analysis of the Effects of Timing Presets on the Performance of H.264/AVC and H.265/HEVC Video Encoders,“ *Edumatic: Jurnal Pendidikan Informatika*, Bd. 5, Rn. 2, S. 187–195, 2021, DOI: 10.29408/edumatic.v5i2.3850.
- [116] S. Neumeier, P. Wintersberger, A.-K. Frison, A. Becher, C. Facchi et al., „Teleoperation: The Holy Grail to Solve Problems of Automated Driving? Sure, but Latency Matters,“ in *Proceedings of the 11th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, 2019, S. 186–197, ISBN: 978-1-4503-6884-1. DOI: 10.1145/3342197.3344534.
- [117] S. R. Ellis, M. J. Young, B. D. Adelstein, M. Field und S. M. Ehrlich, „Discrimination of Changes in Latency during Head Movement,“ in *Proceedings of the HCI International '99 (the 8th International Conference on Human-Computer Interaction) on Human-Computer Interaction: Communication, Cooperation, and Application Design*, 1999, S. 5.
- [118] J. Davis, C. Smyth und K. McDowell, „The Effects of Time Lag on Driving Performance and a Possible Mitigation,“ *IEEE Transactions on Robotics*, Bd. 26, Rn. 3, S. 590–593, 2010, DOI: 10.1109/TRO.2010.2046695.
- [119] X. Shen, Z. J. Chong, S. Pendleton, G. M. James Fu, B. Qin et al., „Teleoperation of On-Road Vehicles via Immersive Telepresence Using Off-the-shelf Components,“ in *Intelligent Autonomous Systems 13*. Bd. 302, E. Menegatti, N. Michael, K. Berns und H. Yamaguchi, Hrsg. Cham: Springer International Publishing, 2016, S. 1419–1433, ISBN: 978-3-319-08337-7 978-3-319-08338-4. DOI: 10.1007/978-3-319-08338-4\_102.
- [120] H. Pongrac, „Gestaltung Und Evaluation von Virtuellen Und Telepräsenzsystemen an Hand von Aufgabenleistung Und Präsenzepfinden,“ Diss., Universität der Bundeswehr, München, 2008. Verfügbar: <https://d-nb.info/101550308X/34>.
- [121] A. Hosseini, „Conception of Advanced Driver Assistance Systems for Precise and Safe Control of Teleoperated Road Vehicles in Urban Environments,“ Diss., Technische Universität München, Garching, 2018.
- [122] M. Sugimoto, G. Kagotani, H. Nii, N. Shiroma, F. Matsuno et al., „Time Follower’s Vision: A Teleoperation Interface with Past Images,“ *IEEE Computer Graphics and Applications*, Bd. 25, Rn. 1, S. 54–63, 2005, DOI: 10.1109/MCG.2005.23.
- [123] F. E. Chucholowski, „Eine vorausschauende Anzeige zur Teleoperation von Straßenfahrzeugen,“ 2016, DOI: 10.13140/RG.2.2.36709.29929.

- [124] G. Graf, Y. Abdelrahman, H. Xu, Y. Abdrabou, D. Schitz et al., „The Predictive Corridor: A Virtual Augmented Driving Assistance System for Teleoperated Autonomous Vehicles,“ *ICAT-EGVE 2020 - International Conference on Artificial Reality and Telexistence and Eurographics Symposium on Virtual Environments*, 9 pages, 2020, ISBN: 9783038681113. DOI: 10.2312/EGVE.20201260.
- [125] S. Sapia, A. Schimpe und L. Ferranti, „Active Safety System for Semi-Autonomous Teleoperated Vehicles,“ in *2021 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops)*, 2021, S. 141–147, ISBN: 978-1-66547-921-9. DOI: 10.1109/IVWorkshops54471.2021.9669239.
- [126] *Springer Handbook of Robotics*, Berlin, Springer, 2008, ISBN: 978-3-540-23957-4.
- [127] S. Weil, J. Freeman, J. Macmillan, C. Jackson, E. Mauer et al., „16. Design of a Multi-Vehicle Control System: System Design and User Interaction,“ in *Advances in Human Performance and Cognitive Engineering Research*. Bd. 7 Elsevier, 2006, S. 223–236, ISBN: 978-0-7623-1247-4. DOI: 10.1016/S1479-3601(05)07016-5.
- [128] A. Schimpe und F. Diermeyer, „Steer with Me: A Predictive, Potential Field-Based Control Approach for Semi-Autonomous, Teleoperated Road Vehicles,“ in *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*, 2020, S. 1–6, ISBN: 978-1-72814-149-7. DOI: 10.1109/ITSC45102.2020.9294702.
- [129] D. Schitz, G. Graf, D. Rieth und H. Aschemann, „Corridor-Based Shared Autonomy for Teleoperated Driving,“ *IFAC-PapersOnLine*, Bd. 53, Rn. 2, S. 15368–15373, 2020, DOI: 10.1016/j.ifacol.2020.12.2351.
- [130] T. L. T. Chen, „Methods for Improving the Control of Teleoperated Vehicles,“ Diss., Technische Universität München, Garching, 2015. Verfügbar: <https://mediatum.ub.tum.de/doc/1236115/1236115.pdf>.
- [131] M. Fennel, A. Zea und U. D. Hanebeck, „Haptic-Guided Path Generation for Remote Car-Like Vehicles,“ *IEEE Robotics and Automation Letters*, Bd. 6, Rn. 2, S. 4087–4094, 2021, DOI: 10.1109/LRA.2021.3067846.
- [132] T. Nützel, „AI-based Movement Planning for Autonomous and Teleoperated Vehicles Including the Development of a Simulation Environment and an Intelligent Agent,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [133] R. Bezak, „Entwicklung Und Erprobung Eines Neuronalen Netzes Zur Automatisierten Fahrzeugführung Für Das Teleoperierte Fahren,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [134] F. Flemisch, C. A. Adams, S. R. Conway, K. H. Goodrich, M. T. Palmer et al., „The H-Metaphor as a Guideline for Vehicle Automation and Interaction,“ NTRS, Rep. NASA/TM-2003-212672 WORK\_UNIT: WU 23-786-10-10, 12.01.2003.
- [135] J.-S. Kim und J.-H. Ryu, „Shared Teleoperation of a Vehicle with a Virtual Driving Interface,“ in *2013 13th International Conference on Control, Automation and Systems (ICCAS 2013)*, 2013, S. 851–857, ISBN: 978-89-93215-05-2. DOI: 10.1109/ICCAS.2013.6704032.
- [136] S. Gnatzig, „Trajektorienbasierte Teleoperation von Straßenfahrzeugen auf Basis eines Shared-Control-Ansatzes,“ Diss., Technische Universität München, Garching, 2015. Verfügbar: <https://mediatum.ub.tum.de/?id=1253158>.

- [137] S. Gnatzig, F. Schuller und M. Lienkamp, „Human-Machine Interaction as Key Technology for Driverless Driving - A Trajectory-Based Shared Autonomy Control Approach,“ in *2012 IEEE RO-MAN: The 21st IEEE International Symposium on Robot and Human Interactive Communication*, 2012, S. 913–918, ISBN: 978-1-4673-4606-1 978-1-4673-4604-7 978-1-4673-4605-4. DOI: 10.1109/ROMAN.2012.6343867.
- [138] J. P. Feiler, „Modifizierung der maschinellen Wahrnehmung mittels Teleassistenz,“ Diss., Technische Universität München, Garching, 2022.
- [139] B. Abendroth, *Gestaltungspotentiale für ein PKW-Abstandsregelsystem unter Berücksichtigung verschiedener Fahrertypen*, (Schriftenreihe Ergonomie), Ergonomia-Verl, Stuttgart, 2001, ISBN: 978-3-935089-62-3.
- [140] J. Rasmussen, „Skills, Rules, and Knowledge; Signals, Signs, and Symbols, and Other Distinctions in Human Performance Models,“ *IEEE Transactions on Systems, Man, and Cybernetics*, Bd. SMC-13, Rn. 3, S. 257–266, 1983, DOI: 10.1109/TSMC.1983.6313160.
- [141] M. Endsley, „Situation Awareness Global Assessment Technique (SAGAT),“ in *Proceedings of the IEEE 1988 National Aerospace and Electronics Conference*, 1988, S. 789–795, DOI: 10.1109/NAECON.1988.195097.
- [142] T. Hecht, „Entwicklung eines Modells zur Beschreibung der Beherrschbarkeit eines hochautomatisierten Fahrerassistenzsystems während "Hands Off" Fahrt,“ Masterarbeit, Technische Universität München, Garching, 2017.
- [143] J.-M. Georg, T. Hecht und F. Diermeyer, „Development of a Human Driver Model during Highly Automated Driving for the ASIL Controllability Classification,“ in *8. Tagung Fahrerassistenz*, 2017. Verfügbar: [https://mediatum.ub.tum.de/1142060?show\\_id=1421389](https://mediatum.ub.tum.de/1142060?show_id=1421389).
- [144] T. Sheridan, „Teleoperation, Telerobotics, and Telepresence: A Progress Report,“ *IFAC Proceedings Volumes*, Bd. 25, Rn. 9, S. 1–8, 1992, DOI: 10.1016/S1474-6670(17)50164-0.
- [145] G. Graf, H. Palleis und H. Hussmann, „A Design Space for Advanced Visual Interfaces for Teleoperated Autonomous Vehicles,“ in *Proceedings of the International Conference on Advanced Visual Interfaces*, 2020, S. 1–3, ISBN: 978-1-4503-7535-1. DOI: 10.1145/3399715.3399942.
- [146] J. Veeh, „Entwicklung Und Implementierung Eines Systems Zur Verbesserung Der Telepräsenz Beim Teleoperierten Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [147] J. Scholtz, J. Young, J. Drury und H. Yanco, „Evaluation of Human-Robot Interaction Awareness in Search and Rescue,“ in *IEEE International Conference on Robotics and Automation, 2004. Proceedings. ICRA '04. 2004*, 2004, 2327–2332 Vol.3, ISBN: 978-0-7803-8232-9. DOI: 10.1109/ROBOT.2004.1307409.
- [148] D. W. Hainsworth, „Teleoperation User Interfaces for Mining Robotics,“ *Autonomous Robots*, Bd. 11, Rn. 1, S. 19–28, 2001, DOI: 10.1023/A:1011299910904.
- [149] V. Linkov und M. Vanžura, „Situation Awareness Measurement in Remotely Controlled Cars,“ *Frontiers in Psychology*, Bd. 12, S. 592930, 2021, DOI: 10.3389/fpsyg.2021.592930.
- [150] N. J. Cooke, „Human Factors of Remotely Operated Vehicles,“ *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, Bd. 50, Rn. 1, S. 166–169, 2006, DOI: 10.1177/154193120605000135.

- [151] „Einride Unveils Remote Operator,“ 2023. [Online]. Verfügbar: <https://www.einride.tech/press/einride-unveils-worlds-first-remote-aet-operator-of-autonomous-electric/> [aufgerufen am 23. 07. 2023].
- [152] M. Bout, A. P. Brenden, M. Klingegård, A. Habibovic und M.-P. Böckle, „A Head-Mounted Display to Support Teleoperations of Shared Automated Vehicles,“ in *Proceedings of the 9th International Conference on Automotive User Interfaces and Interactive Vehicular Applications Adjunct - AutomotiveUI '17*, 2017, S. 62–66, ISBN: 978-1-4503-5151-5. DOI: 10.1145/3131726.3131758.
- [153] „Autonome Autos: Tele-Fahrer Gegen Die Angst Vor Dem Kontrollverlust - WELT,“ 2023. [Online]. Verfügbar: <https://www.welt.de/wirtschaft/plus191825051/Autonome-Autos-Tele-Fahrer-gegen-die-Angst-vor-dem-Kontrollverlust.html> [aufgerufen am 23. 07. 2023].
- [154] B. Keyes, R. Casey, H. A. Yanco, B. A. Maxwell und Y. Georgiev, „Camera Placement and Multi-Camera Fusion for Remote Robot Operation,“ 2006. Verfügbar: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=ff45e7110f65ba078222de283973a73c70af7635> [aufgerufen am 23. 02. 2023].
- [155] M. Hofbauer, C. B. Kuhn, G. Petrovic und E. Steinbach, „TELECARLA: An Open Source Extension of the CARLA Simulator for Teleoperated Driving Research Using Off-the-Shelf Components,“ in *2020 IEEE Intelligent Vehicles Symposium (IV)*, 2020, S. 335–340, ISBN: 978-1-72816-673-5. DOI: 10.1109/IV47402.2020.9304676.
- [156] L. Almeida, B. Patrao, P. Menezes und J. Dias, „Be the Robot: Human Embodiment in Tele-Operation Driving Tasks,“ in *The 23rd IEEE International Symposium on Robot and Human Interactive Communication*, 2014, S. 477–482, ISBN: 978-1-4799-6765-0 978-1-4799-6763-6. DOI: 10.1109/ROMAN.2014.6926298.
- [157] J. C. Garcia, B. Patrao, L. Almeida, J. Perez, P. Menezes et al., „A Natural Interface for Remote Operation of Underwater Robots,“ *IEEE Computer Graphics and Applications*, Bd. 37, Rn. 1, S. 34–43, 2017, DOI: 10.1109/MCG.2015.118.
- [158] J. Jankowski und A. Grabowski, „Usability Evaluation of VR Interface for Mobile Robot Teleoperation,“ *International Journal of Human-Computer Interaction*, Bd. 31, Rn. 12, S. 882–889, 2015, DOI: 10.1080/10447318.2015.1039909.
- [159] L. A. Nguyen, M. Bualat, L. J. Edwards, L. Flueckiger, C. Neveu et al., „Virtual Reality Interfaces for Visualization and Control of Remote Vehicles,“ *Autonomous Robots*, Bd. 11, Rn. 1, S. 59–68, 2001, DOI: 10.1023/A:1011208212722.
- [160] *Virtual und Augmented Reality (VR / AR): Grundlagen und Methoden der Virtuellen und Augmentierten Realität*, (eXamen.press), Berlin, Heidelberg, Springer Berlin Heidelberg, 2013, ISBN: 978-3-642-28902-6 978-3-642-28903-3. DOI: 10.1007/978-3-642-28903-3.
- [161] M. Fiala, „Pano-Presence for Teleoperation,“ in *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2005, S. 3798–3802, ISBN: 978-0-7803-8912-0. DOI: 10.1109/IROS.2005.1545298.
- [162] M. Lager und E. A. Topp, „Remote Supervision of an Autonomous Surface Vehicle Using Virtual Reality,“ *IFAC-PapersOnLine*, Bd. 52, Rn. 8, S. 387–392, 2019, DOI: 10.1016/j.ifacol.2019.08.104.
- [163] T. Kot und P. Novák, „Utilization of the Oculus Rift HMD in Mobile Robot Teleoperation,“ *Applied Mechanics and Materials*, Bd. 555, S. 199–208, 2014, DOI: 10.4028/www.scientific.net/AMM.555.199.

- [164] A. Hosseini und M. Lienkamp, „Enhancing Telepresence during the Teleoperation of Road Vehicles Using HMD-based Mixed Reality,“ in *2016 IEEE Intelligent Vehicles Symposium (IV)*, 2016, S. 1366–1373, ISBN: 978-1-5090-1821-5. DOI: 10/ggfv6s.
- [165] S. Kalamkar, V. Biener, F. Beck und J. Grubert. „Remote Monitoring and Teleoperation of Autonomous Vehicles – Is Virtual Reality an Option?,“ 2023. [Online]. Verfügbar: <http://arxiv.org/abs/2304.11228> [aufgerufen am 29. 07. 2023].
- [166] C. Nielsen, M. Goodrich und R. Ricks, „Ecological Interfaces for Improving Mobile Robot Teleoperation,“ *IEEE Transactions on Robotics*, Bd. 23, Rn. 5, S. 927–941, 2007, DOI: 10.1109/TRO.2007.907479.
- [167] D. Labonte, P. Boissy und F. Michaud, „Comparative Analysis of 3-D Robot Teleoperation Interfaces With Novice Users,“ *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, Bd. 40, Rn. 5, S. 1331–1342, 2010, DOI: 10.1109/TSMCB.2009.2038357.
- [168] „Vuze+ Camera | Vuze Camera,“ 2023. [Online]. Verfügbar: <https://vuze.camera/camera/vuze-plus-camera> [aufgerufen am 29. 07. 2023].
- [169] B. A. Maxwell, L. A. Meeden, N. S. Addo, P. Dickson, N. Fairfield et al., „Reaper: A Reflexive Architecture for Perceptive Agents,“ *AI Magazine*, Bd. 22, Rn. 1, S. 53–66, 2001, DOI: 10.1609/aimag.v22i1.1543. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1609/aimag.v22i1.1543>.
- [170] K. Kruckel, F. Nolden, A. Ferrein und I. Scholl, „Intuitive Visual Teleoperation for UGVs Using Free-Look Augmented Reality Displays,“ in *2015 IEEE International Conference on Robotics and Automation (ICRA)*, 2015, S. 4412–4417, ISBN: 978-1-4799-6923-4. DOI: 10.1109/ICRA.2015.7139809.
- [171] P. Meyersieck, „Erweiterung Und Evaluierung Eines Virtual Reality Anzeigeconzeptes Für Das Teleoperierte Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2017.
- [172] F. Tener und J. Lanir, „Driving from a Distance: Challenges and Guidelines for Autonomous Vehicle Teleoperation Interfaces,“ in *CHI Conference on Human Factors in Computing Systems*, 2022, S. 1–13, ISBN: 978-1-4503-9157-3. DOI: 10.1145/3491102.3501827.
- [173] M. M. Glumm, P. W. Kilduff und A. S. Masley, „A Study of the Effects of Focal Length on Remote Driver Performance,“ *ARL-TR-25, Army Research Laboratory*, S. 35, 1992.
- [174] K. W. Arthur, *Effects of Field of View on Performance with Head-Mounted Displays*, The University of North Carolina at Chapel Hill, 2000, ISBN: 978-0-599-73372-5.
- [175] J. Wang, M. Lewis und S. Hughes, „Gravity-Referenced Attitude Display for Teleoperation of Mobile Robots,“ *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, Bd. 48, Rn. 23, S. 2662–2666, 2004, DOI: 10.1177/154193120404802312.
- [176] S. Hoffmann, F. Willert, M. Hofbauer, A. Schimpe und F. Diermeyer, „Quantifying the Influence of Image Quality on Operator Reaction Times for Teleoperated Road Vehicles,“ 2022, DOI: 10.54941/ahfe1002322.
- [177] C. Cruz-Neira, D. J. Sandin, T. A. DeFanti, R. V. Kenyon und J. C. Hart, „The CAVE: Audio Visual Experience Automatic Virtual Environment,“ *Communications of the ACM*, Bd. 35, Rn. 6, S. 64–72, 1992, DOI: 10.1145/129888.129892.

- [178] R. Dörner, W. Broll, P. Grimm und B. Jung, „Virtual Reality und Augmented Reality (VR/AR): Auf dem Weg von der Nische zum Massenmarkt,“ *Informatik-Spektrum*, Bd. 39, Rn. 1, S. 30–37, 2016, DOI: 10.1007/s00287-014-0838-9.
- [179] M. Hofbauer, C. B. Kuhn, G. Petrovic und E. Steinbach, „Preprocessor Rate Control for Adaptive Multi-View Live Video Streaming Using a Single Encoder,“ *IEEE Transactions on Circuits and Systems for Video Technology*, Bd. 32, Rn. 8, S. 5551–5565, 2022, DOI: 10.1109/TCSVT.2022.3142403.
- [180] N. Barman, S. Zadtootaghaj, S. Schmidt, M. G. Martini und S. Möller, „An Objective and Subjective Quality Assessment Study of Passive Gaming Video Streaming,“ *International Journal of Network Management*, Bd. 30, Rn. 3, 2020, DOI: 10.1002/nem.2054.
- [181] M. Vranjes, S. Rimac-Drlje und D. Zagar, „Objective Video Quality Metrics,“ in *ELMAR 2007*, 2007, S. 45–49, ISBN: 978-953-7044-05-3. DOI: 10.1109/ELMAR.2007.4418797.
- [182] S. Lee und G. J. Kim, „Effects of Haptic Feedback, Stereoscopy, and Image Resolution on Performance and Presence in Remote Navigation,“ *International Journal of Human-Computer Studies*, Bd. 66, Rn. 10, S. 701–717, 2008, DOI: 10.1016/j.ijhcs.2008.05.001.
- [183] J. P. McIntire, P. R. Havig und E. E. Geiselman, „What Is 3D Good for? A Review of Human Performance on Stereoscopic 3D Displays,“ 2012, S. 83830X, DOI: 10.1117/12.920017.
- [184] H. Badino, D. Huber und T. Kanade, „Integrating LIDAR into Stereo for Fast and Improved Disparity Computation,“ in *2011 International Conference on 3D Imaging, Modeling, Processing, Visualization and Transmission*, 2011, S. 405–412, ISBN: 978-1-61284-429-9. DOI: 10.1109/3DIMPVT.2011.58.
- [185] R. Xiaogang, Y. Wenjing, H. Jing, G. Peiyuan und G. Wei, „Monocular Depth Estimation Based on Deep Learning: A Survey,“ in *2020 Chinese Automation Congress (CAC)*, 2020, S. 2436–2440, ISBN: 978-1-72817-687-1. DOI: 10.1109/CAC51589.2020.9327548.
- [186] J. L. Drury, B. Keyes und H. A. Yanco, „LASSOing HRI: Analyzing Situation Awareness in Map-Centric and Video-Centric Interfaces,“ in *Proceedings of the ACM/IEEE International Conference on Human-robot Interaction*, 2007, S. 279–286, ISBN: 978-1-59593-617-2. DOI: 10.1145/1228716.1228754.
- [187] F. Chucholowski, S. Büchner, J. Reicheneder und M. Lienkamp, „Prediction Methods for Teleoperated Road Vehicles,“ 2013, DOI: 10.13140/2.1.1470.3048.
- [188] Ruike Ren, Wei Wang, Jinze Liu, Yan Li und Li Wang, „Teleoperation of Unmanned Ground Vehicles Based on 3D Trajectory Prediction,“ in *2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*, 2016, S. 790–794, ISBN: 978-1-4673-9613-4. DOI: 10.1109/IMCEC.2016.7867318.
- [189] B. Tam, N. Kottege und B. Kusy, „Augmented Telepresence for Remote Inspection with Legged Robots,“ in *Australasian Conference on Robotics and Automation*, 2017, S. 9, ISBN: 978-1-5108-6011-7.
- [190] C. D. Wickens, „Situation Awareness: Its Applications Value and Its Fuzzy Dichotomies,“ *Journal of Cognitive Engineering and Decision Making*, Bd. 9, Rn. 1, S. 90–94, 2015, DOI: 10.1177/1555343414564571.
- [191] F. Zhou, X. J. Yang und X. Zhang, „Takeover Transition in Autonomous Vehicles: A YouTube Study,“ *International Journal of Human-Computer Interaction*, Bd. 36, Rn. 3, S. 295–306, 2020, DOI: 10.1080/10447318.2019.1634317.



- [192] L. Niklasson, M. Riveiro, F. Johansson, A. Dahlbom, G. Falkman et al., „A Unified Situation Analysis Model for Human and Machine Situation Awareness,“ in *INFORMATIK 2007: Informatik Trifft Logistik*, 2007.
- [193] J. C. Lo, E. Sehic, K. A. Brookhuis und S. A. Meijer, „Explicit or Implicit Situation Awareness? Measuring the Situation Awareness of Train Traffic Controllers,“ *Transportation Research Part F: Traffic Psychology and Behaviour*, Bd. 43, S. 325–338, 2016, DOI: 10.1016/j.trf.2016.09.006.
- [194] L. J. Gugerty, „Situation Awareness during Driving: Explicit and Implicit Knowledge in Dynamic Spatial Memory.“ *Journal of Experimental Psychology: Applied*, Bd. 3, Rn. 1, S. 42–66, 1997, DOI: 10.1037/1076-898X.3.1.42.
- [195] M. R. Endsley, „Situation Awareness Misconceptions and Misunderstandings,“ *Journal of Cognitive Engineering and Decision Making*, Bd. 9, Rn. 1, S. 4–32, 2015, DOI: 10.1177/1555343415572631.
- [196] C. A. Bolstad, H. M. Cuevas, J. Wang-Costello, M. R. Endsley und L. S. Angell, „Measurement of Situation Awareness for Automobile Technologies of the Future,“ in *Measurement of Situation Awareness for Automobile Technologies of the Future*. ISBN: 978-0-7680-6148-2. Verfügbar: <https://doi.org/10.4271/R-402>.
- [197] M. R. Endsley, „Situation Awareness in Future Autonomous Vehicles: Beware of the Unexpected,“ in *Proceedings of the 20th Congress of the International Ergonomics Association (IEA 2018)*. Bd. 824, S. Bagnara, R. Tartaglia, S. Albolino, T. Alexander und Y. Fujita, Hrsg. Cham: Springer International Publishing, 2019, S. 303–309, ISBN: 978-3-319-96070-8 978-3-319-96071-5. DOI: 10.1007/978-3-319-96071-5\_32.
- [198] R. Ma und D. B. Kaber, „Situation Awareness and Workload in Driving While Using Adaptive Cruise Control and a Cell Phone,“ *International Journal of Industrial Ergonomics*, Bd. 35, Rn. 10, S. 939–953, 2005, DOI: 10.1016/j.ergon.2005.04.002.
- [199] M. R. Endsley, „Design and Evaluation for Situation Awareness Enhancement,“ *Proceedings of the Human Factors Society Annual Meeting*, Bd. 32, Rn. 2, S. 97–101, 1988, DOI: 10.1177/154193128803200221.
- [200] M. Endsley, „Situation Awareness in Driving,“ in *D. Fisher, W. J. Horrey, J. D. Lee, & M. Regan (Eds.), Handbook of Human Factors for Automated, Connected and Intelligent Vehicles*. London: Taylor and Francis: 2020, ISBN: 978-1-315-26968-9.
- [201] C. D. Wickens, „Situation Awareness and Workload in Aviation,“ *Current Directions in Psychological Science*, Bd. 11, Rn. 4, S. 128–133, 2002, DOI: 10.1111/1467-8721.00184.
- [202] J. L. Burke und R. R. Murphy, „Situation Awareness and Task Performance in Robot-Assisted Technical Search: Bujold Goes to Bridg,“ 2004. Verfügbar: <https://api.semanticscholar.org/CorpusID:15004193> [aufgerufen am 31. 03. 2023].
- [203] J. G. Tromp, „Presence, Telepresence and Immersion,“ in *Proceedings of FIVE'95, Frameworks for Immersive Virtual Environments*, 1995.
- [204] M. Slater und S. Wilbur, „A Framework for Immersive Virtual Environments (FIVE): Speculations on the Role of Presence in Virtual Environments,“ *Presence: Teleoperators and Virtual Environments*, Bd. 6, Rn. 6, S. 603–616, 1997, DOI: 10.1162/pres.1997.6.6.603.
- [205] M. Lombard, R. Reich, M. Grabe, C. Bracken und T. Ditton, „Presence and Television...: The Role of Screen Size,“ *Human Communication Research*, Bd. 26, Rn. 1, S. 75–98, 2000, DOI: 10.1111/j.1468-2958.2000.tb00750.x.

- [206] B. G. Witmer und M. J. Singer, „Measuring Presence in Virtual Environments: A Presence Questionnaire,“ *Presence: Teleoperators and Virtual Environments*, Bd. 7, Rn. 3, S. 225–240, 1998, DOI: 10.1162/105474698565686.
- [207] A. B. Craig, „What Is Augmented Reality?,“ in *Understanding Augmented Reality* Elsevier, 2013, S. 1–37, ISBN: 978-0-240-82408-6. DOI: 10.1016/B978-0-240-82408-6.00001-1.
- [208] M. Minsky, „Telepresence,“ *Omni*, June 1980, Bd. Vol. 2 No. 9, S. 132, 1980.
- [209] J. M. Riley und D. B. Kaber, „Utility of Situation Awareness and Attention for Describing Telepresence Experiences in a Virtual Teleoperation Task,“ 2001.
- [210] W. IJsselsteijn, H. de Ridder, J. Freeman, S. E. Avons und D. Bouwhuis, „Effects of Stereoscopic Presentation, Image Motion, and Screen Size on Subjective and Objective Corroborative Measures of Presence,“ *Presence: Teleoperators and Virtual Environments*, Bd. 10, Rn. 3, S. 298–311, 2001, DOI: 10.1162/105474601300343621.
- [211] H. Regenbrecht, „Factors for the sense of presence within virtual architecture Faktoren für Präsenz in virtueller Architektur,“ Bauhaus-Universität Weimar, 2004, DOI: 10.25643/BAUHAUS-UNIVERSITAET.33.
- [212] L. Schmidt, J. Hegenberg und L. Cramar, „User Studies on Teleoperation of Robots for Plant Inspection,“ *Industrial Robot: An International Journal*, Bd. 41, Rn. 1, S. 6–14, 2014, DOI: 10.1108/IR-02-2013-325.
- [213] R. Chellali und K. Baizid, „What Maps and What Displays for Remote Situation Awareness and ROV Localization?,“ in *Human Interface and the Management of Information. Interacting with Information*. Bd. 6772, G. Salvendy und M. J. Smith, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, S. 364–372, ISBN: 978-3-642-21668-8 978-3-642-21669-5. DOI: 10.1007/978-3-642-21669-5\_43.
- [214] D. de Waard, *The Measurement of Drivers' Mental Workload*, Groningen, Rijksuniv, 1996, ISBN: 978-90-6807-308-9.
- [215] D. R. Thomson, D. Besner und D. Smilek, „A Resource-Control Account of Sustained Attention: Evidence From Mind-Wandering and Vigilance Paradigms,“ *Perspectives on Psychological Science*, Bd. 10, Rn. 1, S. 82–96, 2015, DOI: 10.1177/1745691614556681.
- [216] M. R. Endsley, *Designing for Situation Awareness: An Approach to User-Centered Design*, 2nd ed, Boca Raton, FL, CRC Press, 2011, ISBN: 978-1-4200-6355-4.
- [217] *EN ISO 9241-110 Ergonomie Der Mensch-System-Interaktion*, (Ergonomie Der Mensch-System-Interaktion). Bd. Grundsätze der Dialoggestaltung, Deutsches Institut für Normung e. V., 2006.
- [218] *EN ISO 9241-210 Ergonomie Der Mensch-System-Interaktion Teil 210: Prozess Zur Gestaltung Gebrauchstauglicher Interaktiver Systeme*, (Ergonomie Der Mensch-System-Interaktion). Bd. Grundsätze der Dialoggestaltung, Deutsches Institut für Normung e. V., 2006.
- [219] J. Davis, C. Smyth und K. McDowell, „Mitigating the Effects of Time Lag on Driving Performance,“ in *Proceedings of the 2009 Ground Vehicle Systems Engineering and Technology Symposium*, 2009, S. 5.
- [220] D. Majstorovic und F. Diermeyer, „Dynamic Collaborative Path Planning for Remote Assistance of Highly-Automated Vehicles,“ 2023, DOI: 10.48550/ARXIV.2308.15167.

- [221] J.-M. Georg, J. Feiler, F. Diermeyer und M. Lienkamp, „Teleoperated Driving, a Key Technology for Automated Driving? Comparison of Actual Test Drives with a Head Mounted Display and Conventional Monitors\*,“ in *2018 21st IEEE International Conference on Intelligent Transportation Systems (ITSC)*, 2018, S. 3403–3408, ISBN: 978-1-72810-321-1. DOI: 10.1109/ITSC.2018.8569408.
- [222] C. Mutzenich, S. Durant, S. Helman und P. Dalton, „Situation Awareness in Remote Operators of Autonomous Vehicles: Developing a Taxonomy of Situation Awareness in Video-Relays of Driving Scenes,“ *Frontiers in Psychology*, Bd. 12, S. 727500, 2021, DOI: 10.3389/fpsyg.2021.727500.
- [223] T. Tang, J. Kurkowski und M. Lienkamp, „Teleoperated Road Vehicles: A Novel Study on the Effect of Blur on Speed Perception,“ *International Journal of Advanced Robotic Systems*, Bd. 10, Rn. 9, S. 333, 2013, DOI: 10.5772/56735.
- [224] A. Kelly, N. Chan, H. Herman, D. Huber, R. Meyers et al., „Real-Time Photorealistic Virtualized Reality Interface for Remote Mobile Robot Control,“ *The International Journal of Robotics Research*, Bd. 30, Rn. 3, S. 384–404, 2011, DOI: 10.1177/0278364910383724.
- [225] O. Bodell, „Teleoperation of Autonomous Vehicle - With 360° Camera Feedback,“ Masterarbeit, Chalmers University of Technology, Gothenburg, Sweden, 2016.
- [226] D. J. Bruemmer, D. A. Few, M. C. Walton, R. L. Boring, J. L. Marble et al., „Turn Off the Television!\": Real-World Robotic Exploration Experiments with a Virtual 3-D Display,“ *th Hawaii International Conference on System Sciences*, S. 8, 2005.
- [227] J. Y. C. Chen, R. N. V. Oden, C. Kenny und J. O. Merritt, „Stereoscopic Displays for Robot Teleoperation and Simulated Driving,“ *th ANNUAL MEETING*, 2010.
- [228] R. Parasuraman, S. Caccamo, F. Båberg, P. Ögren und M. Neerincx. „A New UGV Teleoperation Interface for Improved Awareness of Network Connectivity and Physical Surroundings,“ 2023. [Online]. Verfügbar: <http://arxiv.org/abs/1710.06785> [aufgerufen am 13. 01. 2023].
- [229] R. Chellali, K. Baizid und Z. Li, „2D and 3D Virtual Environment for Human Robot Interaction: From Virtual Perception to Real Localization,“ in *2009 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, 2009, S. 694–699, ISBN: 978-1-4244-4774-9. DOI: 10.1109/ROBIO.2009.5420590.
- [230] L. Peppoloni, F. Brizzi, C. A. Avizzano und E. Ruffaldi, „Immersive ROS-integrated Framework for Robot Teleoperation,“ in *2015 IEEE Symposium on 3D User Interfaces (3DUI)*, 2015, S. 177–178, ISBN: 978-1-4673-6886-5. DOI: 10.1109/3DUI.2015.7131758.
- [231] D. S. Pamungkas und K. Ward, „Electro-Tactile Feedback System for Achieving Embodiment in a Tele-Operated Robot,“ in *2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, 2014, S. 1706–1711, ISBN: 978-1-4799-5199-4. DOI: 10.1109/ICARCV.2014.7064573.
- [232] Y. Luo, J. Wang, R. Shi, H.-N. Liang und S. Luo. „In-Device Feedback in Immersive Head-Mounted Displays for Distance Perception During Teleoperation of Unmanned Ground Vehicles,“ 2023. [Online]. Verfügbar: <http://arxiv.org/abs/2201.03036> [aufgerufen am 20. 02. 2023].
- [233] T. Sheridan, „Telerobotics,“ *Automatica*, Bd. 25, Rn. 4, S. 487–507, 1989, DOI: 10.1016/005-1098(89)90093-9.

- [234] S. Livatino, D. C. Guastella, G. Muscato, V. Rinaldi, L. Cantelli et al., „Intuitive Robot Teleoperation Through Multi-Sensor Informed Mixed Reality Visual Aids,“ *IEEE Access*, Bd. 9, S. 25795–25808, 2021, DOI: 10.1109/ACCESS.2021.3057808.
- [235] L. Almeida, P. Menezes und J. Dias, „Improving Robot Teleoperation Experience via Immersive Interfaces,“ in *2017 4th Experiment@International Conference (Exp.at'17)*, 2017, S. 87–92, ISBN: 978-1-5386-0810-4. DOI: 10.1109/EXPAT.2017.7984414.
- [236] E. Yurtsever, J. Lambert, A. Carballo und K. Takeda, „A Survey of Autonomous Driving: Common Practices and Emerging Technologies,“ *IEEE Access*, Bd. 8, S. 58443–58469, 2020, DOI: 10.1109/ACCESS.2020.2983149. arXiv: 1906.05113 [cs, eess].
- [237] B. Ricaud, R. Lietar und C. Joly, „Are Virtual Reality Headsets Efficient for Remote Driving?,“ 2015, DOI: hal01510779.
- [238] S. Ruano, C. Cuevas, G. Gallego und N. García, „Augmented Reality Tool for the Situational Awareness Improvement of UAV Operators,“ *Sensors*, Bd. 17, Rn. 2, S. 297, 2017, DOI: 10.3390/s17020297.
- [239] R. E. Bailey, J. I. Arthur, S. P. Williams und L. Kramer, „Latency in Visionic Systems: Test Methods and Requirements,“ in *Workshop on Toward Recommended Methods for Testing and Evaluation of EV and ESV Based Visionic Devices*, 2005, S. 14.
- [240] A. Hosseini, T. Wiedemann und M. Lienkamp, „Interactive Path Planning for Teleoperated Road Vehicles in Urban Environments,“ in *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2014, S. 400–405, ISBN: 978-1-4799-6078-1. DOI: 10.1109/ITSC.2014.6957723.
- [241] A. Hosseini und M. Lienkamp, „Predictive Safety Based on Track-before-Detect for Teleoperated Driving through Communication Time Delay,“ in *2016 IEEE Intelligent Vehicles Symposium (IV)*, 2016, S. 165–172, ISBN: 978-1-5090-1821-5. DOI: 10.1109/IVS.2016.7535381.
- [242] S. Gnatzig, F. Chucholowski, T. Tang und M. Lienkamp, „A System Design for Teleoperated Road Vehicles,“ in *Conference: Proceedings of the 10th International Conference on Informatics in Control, Automation and Robotics*, 2013, S. 6.
- [243] J. Nielsen, *Usability Engineering*, Morgan Kaufmann, 1994, ISBN: 978-0-12-518406-9.
- [244] S. G. Hart, „Nasa-Task Load Index (NASA-TLX); 20 Years Later,“ *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, Bd. 50, Rn. 9, S. 904–908, 2006, DOI: 10.1177/154193120605000909.
- [245] C. Kettwich und A. Dreßler, „Requirements of Future Control Centers in Public Transport,“ in *12th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, 2020, S. 69–73, ISBN: 978-1-4503-8066-9. DOI: 10.1145/3409251.3411726.
- [246] G. Adamides, G. Christou, C. Katsanos, M. Xenos und T. Hadzilacos, „Usability Guidelines for the Design of Robot Teleoperation: A Taxonomy,“ *IEEE Transactions on Human-Machine Systems*, Bd. 45, Rn. 2, S. 256–262, 2015, DOI: 10.1109/THMS.2014.2371048.
- [247] J. L. Drury, D. Hestand, H. A. Yanco und J. Scholtz, „Design Guidelines for Improved Human-Robot Interaction,“ in *CHI '04 Extended Abstracts on Human Factors in Computing Systems*, 2004, S. 1540–1540, ISBN: 978-1-58113-703-3. DOI: 10.1145/985921.986116.
- [248] T. Fong und C. Thorpe, „Vehicle Teleoperation Interfaces,“ *Autonomous Robots*, Bd. 11, Rn. 1, S. 9–18, 2001, DOI: 10.1023/A:1011295826834.

- [249] J.-M. Georg und F. Diermeyer, „An Adaptable and Immersive Real Time Interface for Resolving System Limitations of Automated Vehicles with Teleoperation,“ in *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, 2019, S. 2659–2664, ISBN: 978-1-72814-569-3. DOI: 10.1109/SMC.2019.8914306.
- [250] „ADTF,“ 2023. [Online]. Verfügbar: <https://www.elektrobit.com/products/automated-driving/eb-assist/adtf/> [aufgerufen am 16. 03. 2023].
- [251] „ROS - Robot Operating System,“ 2023. [Online]. Verfügbar: <https://www.ros.org/> [aufgerufen am 07. 03. 2023].
- [252] „OpenGL,“ 2023. [Online]. Verfügbar: <https://www.opengl.org/> [aufgerufen am 07. 03. 2023].
- [253] M. Bailey. „The Computer Graphics Process and the Graphics Pipeline“, (Oregon State University). 26 July 20221.
- [254] „Open Asset Import Library (Assimp),“ Open Asset Import Library, 10. Sep. 2023. Verfügbar: <https://github.com/assimp/assimp> [aufgerufen am 10. 09. 2023].
- [255] D. Scaramuzza, A. Martinelli und R. Siegwart, „A Flexible Technique for Accurate Omnidirectional Camera Calibration and Structure from Motion,“ in *Fourth IEEE International Conference on Computer Vision Systems (ICVS'06)*, 2006, S. 45–45, ISBN: 978-0-7695-2506-8. DOI: 10.1109/ICVS.2006.3.
- [256] D. Scaramuzza. „OCamCalib: Omnidirectional Camera Calibration Toolbox for Matlab,“ 2023. [Online]. Verfügbar: <https://sites.google.com/site/scarobotix/ocamcalib-omnidirectional-camera-calibration-toolbox-for-matlab?pli=1> [aufgerufen am 11. 01. 2023].
- [257] V. Bilonenko. „Delaunator-Cpp, A Really Fast C++ Library for Delaunay Triangulation of 2D Points.“ 2023. [Online]. Verfügbar: <https://github.com/delfrrr/delaunator-cpp> [aufgerufen am 09. 03. 2023].
- [258] F. Wagner, „Erstellung Einer Auf Voxel Basierenden Hochgenauen Karte Mithilfe von LiDAR Und Kameradaten,“ Masterarbeit, Technische Universität München, Garching, 2019.
- [259] S. S. Intelligence. „LMS200/211/221/291 Laser Measurement Systems. Technical Information,“ 2023. [Online]. Verfügbar: [https://www.sick.com/media/pdf/9/49/849/dataSheet\\_LMS291-S05\\_1018028\\_en.pdf](https://www.sick.com/media/pdf/9/49/849/dataSheet_LMS291-S05_1018028_en.pdf) [aufgerufen am 10. 03. 2023].
- [260] F. Franke, „Development and Evaluation of a Camera Concept for an Human Machine Interface Based on the HTC-VivePro and Gaming Displays for Highly Automated or Teleoperated Driving,“ Masterarbeit, Technische Universität München, Garching, 2019.
- [261] F. Nenci, L. Spinello und C. Stachniss, „Effective Compression of Range Data Streams for Remote Robot Operations Using H.264,“ in *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2014, S. 3794–3799, ISBN: 978-1-4799-6934-0 978-1-4799-6931-9. DOI: 10.1109/IROS.2014.6943095.
- [262] M. Betz, „Entwicklung Einer Sensordatenfusion Zur Visualisierung von LiDAR- Und Kameradaten Für Das Teleoperierte Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2019.
- [263] E. Putz, „Entwicklung Einer Methode Zur Evaluierung Des Einflusses Der Videoqualität Auf Die Informationsaufnahme Bei Der Teleoperation von Automatisierten Fahrzeugen,“ Bachelorarbeit, Technische Universität München, 2019.
- [264] S. Guggenmoss, „Entwicklung Und Durchführung Einer Studie Zum Vergleich von Verschiedenen Mensch-Maschine-Schnittstellen Für Die Teleoperation von Autonomen Fahrzeugen,“ 2021.

- [265] J.-M. Georg, E. Putz und F. Diermeyer, „Longtime Effects of Videoquality, Videocanvases and Displays on Situation Awareness during Teleoperation of Automated Vehicles,“ in *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2020, S. 248–255, ISBN: 978-1-72818-526-2. DOI: 10.1109/SMC42975.2020.9283364.
- [266] C. Gold, M. Körber, D. Lechner und K. Bengler, „Taking Over Control From Highly Automated Vehicles in Complex Traffic Situations: The Role of Traffic Density,“ *Human Factors: The Journal of the Human Factors and Ergonomics Society*, Bd. 58, Rn. 4, S. 642–652, 2016, DOI: 10.1177/0018720816634226.
- [267] C. Gold und H. Alexander, „Beherrschbarkeit Hochautomatisierter Fahrzeugführung - Zwischen Übernahmezeit Und Zeitbudget,“ 2016, S. 42–53, ISBN: 978-3-8169-3365-6.
- [268] K. Zeeb, A. Buchner und M. Schrauf, „What Determines the Take-over Time? An Integrated Model Approach of Driver Take-over after Automated Driving,“ *Accident Analysis & Prevention*, Bd. 78, S. 212–221, 2015, DOI: 10.1016/j.aap.2015.02.023.
- [269] M. Richter und M. D. Flückiger, *Usability Engineering kompakt*, (IT kompakt), Berlin, Heidelberg, Springer Berlin Heidelberg, 2013, ISBN: 978-3-642-34831-0 978-3-642-34832-7. DOI: 10.1007/978-3-642-34832-7.
- [270] A. Bruun und J. Stage, „An Empirical Study of the Effects of Three Think-Aloud Protocols on Identification of Usability Problems,“ in *Human-Computer Interaction – INTERACT 2015*. Bd. 9297, J. Abascal, S. Barbosa, M. Fetter, T. Gross, P. Palanque et al., Hrsg. Cham: Springer International Publishing, 2015, S. 159–176, ISBN: 978-3-319-22667-5 978-3-319-22668-2. DOI: 10.1007/978-3-319-22668-2\_14.
- [272] „Fahrsimulation Und SILAB,“ 2023. [Online]. Verfügbar: <https://wivw.de/de/silab> [aufgerufen am 16. 09. 2023].
- [273] „LimeSurvey – Kostenloses Online-Umfrage-Tool,“ 2023. [Online]. Verfügbar: <https://www.limesurvey.org/de> [aufgerufen am 16. 09. 2023].
- [274] M. R. Endsley. „Direct Measurement of Situation Awareness: Validity and Use of SA-GAT,“ in: E. Salas und A. S. Dietz. *Situational Awareness*. Hrsg. von E. Salas. 1. Aufl. Routledge, 5. Juli 2017, S. 129–156. ISBN: 978-1-315-08792-4. DOI: 10.4324/9781315087924-9.
- [275] M. Hofbauer, C. B. Kuhn, L. Puttner, G. Petrovic und E. Steinbach, „Measuring Driver Situation Awareness Using Region-of-Interest Prediction and Eye Tracking,“ in *2020 IEEE International Symposium on Multimedia (ISM)*, 2020, S. 91–95, ISBN: 978-1-72818-697-9. DOI: 10.1109/ISM.2020.00022.
- [276] M. Hassenzahl, M. Burmester und F. Koller, „AttrakDiff: Ein Fragebogen zur Messung wahrgenommener hedonischer und pragmatischer Qualität,“ in *Mensch & Computer 2003*. Bd. 57, G. Szwillus und J. Ziegler, Hrsg. Wiesbaden: Vieweg+Teubner Verlag, 2003, S. 187–196, ISBN: 978-3-519-00441-7 978-3-322-80058-9. DOI: 10.1007/978-3-322-80058-9\_19.
- [277] B. Breyer und M. Bluemke, „Deutsche Version der Positive and Negative Affect Schedule PANAS (GESIS Panel),“ *Zusammenstellung sozialwissenschaftlicher Items und Skalen (ZIS)*, 2016, DOI: 10.6102/ZIS242.
- [278] P. D. J. Prümper. „*ISONORM 9241/110 Questionnaire - Evaluation of Software Based on Ergonomic Norm DIN EN ISO 9241-110*,“ usetree, 2008.

- [279] S. G. Hart, „Nasa-Task Load Index (NASA-TLX); 20 Years Later,“ *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, Bd. 50, Rn. 9, S. 904–908, 2006, DOI: 10.1177/154193120605000909.
- [280] F. Hartig. „DHARMa - Residual Diagnostics for HierARchical Models,“ 2023. [Online]. Verfügbar: <https://github.com/florianhartig/DHARMa> [aufgerufen am 10. 04. 2023].
- [281] H.-B. Brosius, A. Haas und F. Koschel, *Methoden der empirischen Kommunikationsforschung*, Wiesbaden, VS Verlag für Sozialwissenschaften, 2016, ISBN: 978-3-531-19995-5 978-3-531-19996-2. DOI: 10.1007/978-3-531-19996-2.
- [282] R. S. Gutzwiller und B. A. Clegg, „The Role of Working Memory in Levels of Situation Awareness,“ *Journal of Cognitive Engineering and Decision Making*, Bd. 7, Rn. 2, S. 141–154, 2013, DOI: 10.1177/1555343412451749.
- [283] E. Jeannot, C. Kelly und D. Thompson, „The Development of Situation Awareness Measures in ATM Systems,“ EUROCONTROL, Rep. HRS/HSP-005-REP-01, 06.2003. Verfügbar: [https://referenceworks.brillonline.com/entries/international-year-book-and-statesmens-who-s-who/\\*-SIM\\_org\\_39214](https://referenceworks.brillonline.com/entries/international-year-book-and-statesmens-who-s-who/*-SIM_org_39214) [aufgerufen am 08. 06. 2023].
- [284] M. R. Endsley, „A Systematic Review and Meta-Analysis of Direct Objective Measures of Situation Awareness: A Comparison of SAGAT and SPAM,“ *Human Factors: The Journal of the Human Factors and Ergonomics Society*, Bd. 63, Rn. 1, S. 124–150, 2021, DOI: 10.1177/0018720819875376.
- [285] J. M. Riley, D. B. Kaber und J. V. Draper, „Situation Awareness and Attention Allocation Measures for Quantifying Telepresence Experiences in Teleoperation,“ *Human Factors and Ergonomics in Manufacturing*, Bd. 14, Rn. 1, S. 51–67, 2004, DOI: 10.1002/hfm.10050.
- [286] M. S. Kadavasal, A. Seth und J. H. Oliver, „Virtual Reality Based Multi-Modal Teleoperation Using Mixed Autonomy,“ in *Volume 3: 28th Computers and Information in Engineering Conference, Parts A and B*, 2008, S. 1451–1460, ISBN: 978-0-7918-4327-7. DOI: 10.1115/DETC2008-49144.
- [287] „. Gesetz Zur Änderung Des Straßenverkehrsgesetzes Und Des Pflichtversicherungsgesetzes - Gesetz Zum Autonomen Fahren,“ 28. Juli 2021. Verfügbar: <https://dip.bundestag.de/vorgang/gesetz-zur-%C3%A4nderung-des-stra%C3%9Fenverkehrsgesetzes-und-des-pflichtversicherungsgesetzes-gesetz/273887?f.deskriptor=Autonomes%20Fahrzeug&rows=25&pos=17> [aufgerufen am 28. 02. 2024].
- [288] D. Marx, „Development and Implementation of a Steering Wheel Torque Estimator Based on Deep Neural Networks for Realistic Haptic Feedback during Teleoperated Driving,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [289] L. Tychsen und L. L. Thio, „Concern of Photosensitive Seizures Evoked by 3D Video Displays or Virtual Reality Headsets in Children: Current Perspective,“ *Eye and Brain*, Bd. Volume 12, S. 45–48, 2020, DOI: 10.2147/EB.S233195.
- [290] S. Zimet. „Apple Vision Pro Is Half the Price of the Apple II,“ 2024. [Online]. Verfügbar: <https://humanprogress.org/apple-vision-pro-is-half-the-price-of-the-apple-ii/> [aufgerufen am 28. 01. 2024].
- [291] J. Wesker, „Vergleich von Teleoperierten Testfahrten Zwischen 4G, 5G Und Dem Menschen,“ Bachelorarbeit, Technische Universität München, Garching, 2018.

- [292] A. Hanuschek, „Entwicklung, Durchführung Und Validierung Eines Tests Zur Messung von Auswirkungen Optischer Und Haptischer Latenzen Auf Die Fahrzeugquerführung,“ Bachelorarbeit, Technische Universität München, Garching, 2017.
- [293] J. Zacharias, „Entwicklung Und Implementierung Eines Deep Learning Algorithmus Zur Erkennung von Fahrbahnmarkierungen,“ Masterarbeit, Technische Universität München, Garching, 2020.
- [294] C. Stadler, „Entwicklung Und Erprobung Eines Notbremsassistenten Für Das Teleoperierte Fahren Auf Basis von Lidar-Distanzmessungen,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [295] F. Li, „Entwicklung Einer Realistischen Simulationsumgebung Für Das Teleoperierte Fahren.Pdf,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [296] Y. Xue, „Entwicklung einer hochgenauen Linienfolgeregelung für einen autonomen Roboter,“ Bachelorarbeit, Technische Universität München, Garching, 2019.
- [297] P. Rief, „Entwicklung Eines Tools Zur Einfachen Planung von Befahrbaren Pfaden Anhand Open Source Kartenmaterial,“ Semesterarbeit, Technische Universität München, Garching, 2017.
- [298] A. Eben, „Entwicklung einer Drohnensteuerung für das Teleoperierte Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [299] F. Becker, „Echtzeitimplementierung Eines Neuronalen Netzes Zur Semantischen Segmentierung von Kameradaten.Pdf,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [300] A. Wiedenmann, „Entwicklung Eines Deep Learning Algorithmus Zur Fahrbahnerkennung,“ Bachelorarbeit, Technische Universität München, Garching, 2017.
- [301] J. Schütz, „Entwicklung Einer Trajektorienfolgeregelung Für Ein Hochenergieeffizientes Elektrofahrzeug,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [302] C. Roghard, „Entwicklung Und Analyse Eines Gesamtsystems Für Das Teleoperierte Fahren in Bezug Auf Technologische Und Wirtschaftliche Realisierbarkeit.“ Semesterarbeit, Technische Universität München, Garching, 2017.



# Veröffentlichungsliste

Während der Anfertigung dieser Dissertation entstanden Veröffentlichungen, Software und Studienarbeiten, in denen Teilaspekte dieser Arbeit vorgestellt wurden.

## Zeitschriften; Scopus/ Web of Science gelistet (peer-reviewed)

### Konferenzen, Magazine, etc.; Scopus/ Web of Science gelistet (peer-reviewed)

- [221] J.-M. Georg, J. Feiler, F. Diermeyer und M. Lienkamp, „Teleoperated Driving, a Key Technology for Automated Driving? Comparison of Actual Test Drives with a Head Mounted Display and Conventional Monitors\*,“ in *2018 21st IEEE International Conference on Intelligent Transportation Systems (ITSC)*, 2018, S. 3403–3408, ISBN: 978-1-72810-321-1. DOI: 10.1109/ITSC.2018.8569408.
- [249] J.-M. Georg und F. Diermeyer, „An Adaptable and Immersive Real Time Interface for Resolving System Limitations of Automated Vehicles with Teleoperation,“ in *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, 2019, S. 2659–2664, ISBN: 978-1-72814-569-3. DOI: 10.1109/SMC.2019.8914306.
- [265] J.-M. Georg, E. Putz und F. Diermeyer, „Longtime Effects of Videoquality, Videocanvases and Displays on Situation Awareness during Teleoperation of Automated Vehicles,“ in *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2020, S. 248–255, ISBN: 978-1-72818-526-2. DOI: 10.1109/SMC42975.2020.9283364.

## Patente

### Zeitschriften, Konferenzen, Magazine, Berichte, Konferenzvorträge und -poster, etc.; nicht Scopus/ Web of Science gelistet

### Nicht-dissertationsrelevante Veröffentlichungen; Scopus/ Web of Science gelistet (peer-reviewed)

- [112] J.-M. Georg, J. Feiler, S. Hoffmann und F. Diermeyer, „Sensor and Actuator Latency during Teleoperation of Automated Vehicles,“ in *2020 IEEE Intelligent Vehicles Symposium (IV)*, 2020, S. 760–766, ISBN: 978-1-72816-673-5. DOI: 10.1109/IV47402.2020.9304802.
- [113] M. Gharba, A. R. Ali, V. Jain, S. Lapoehn, J.-M. Georg et al., „A Reconfigurable 5G Testbed for V2X and Industry 4.0 Applications,“ in *IEEE Globecom Workshop on 5G Test-Beds & Trials*, 2017, S. 5. Verfügbar: <https://elib.dlr.de/113143/>.

- [143] J.-M. Georg, T. Hecht und F. Diermeyer, „Development of a Human Driver Model during Highly Automated Driving for the ASIL Controllability Classification,“ in *8. Tagung Fahrerassistenz*, 2017. Verfügbar: [https://mediatum.ub.tum.de/1142060?show\\_id=1421389](https://mediatum.ub.tum.de/1142060?show_id=1421389).

## Dissertationsrelevante Open-Source Software

### Betreute Studienarbeiten

- [132] T. Nützel, „AI-based Movement Planning for Autonomous and Teleoperated Vehicles Including the Development of a Simulation Environment and an Intelligent Agent,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [133] R. Bezak, „Entwicklung Und Erprobung Eines Neuronalen Netzes Zur Automatisierten Fahrzeugführung Für Das Teleoperierte Fahren,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [142] T. Hecht, „Entwicklung eines Modells zur Beschreibung der Beherrschbarkeit eines hochautomatisierten Fahrerassistenzsystems während "Hands OffFahrt,“ Masterarbeit, Technische Universität München, Garching, 2017.
- [146] J. Veeh, „Entwicklung Und Implementierung Eines Systems Zur Verbesserung Der Telepräsenz Beim Teleoperierten Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [171] P. Meyersieck, „Erweiterung Und Evaluierung Eines Virtual Reality Anzeigekonzeptes Für Das Teleoperierte Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2017.
- [258] F. Wagner, „Erstellung Einer Auf Voxel Basierenden Hochgenauen Karte Mithilfe von LiDAR Und Kameradaten,“ Masterarbeit, Technische Universität München, Garching, 2019.
- [260] F. Franke, „Development and Evaluation of a Camera Concept for an Human Machine Interface Based on the HTC-VivePro and Gaming Displays for Highly Automated or Teleoperated Driving,“ Masterarbeit, Technische Universität München, Garching, 2019.
- [262] M. Betz, „Entwicklung Einer Sensordatenfusion Zur Visualisierung von LiDAR- Und Kameradaten Für Das Teleoperierte Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2019.
- [263] E. Putz, „Entwicklung Einer Methode Zur Evaluierung Des Einflusses Der Videoqualität Auf Die Informationsaufnahme Bei Der Teleoperation von Automatisierten Fahrzeugen,“ Bachelorarbeit, Technische Universität München, 2019.
- [264] S. Guggenmoss, „Entwicklung Und Durchführung Einer Studie Zum Vergleich von Verschiedenen Mensch-Maschine-Schnittstellen Für Die Teleoperation von Autonomen Fahrzeugen,“ 2021.
- [288]\* D. Marx, „Development and Implementation of a Steering Wheel Torque Estimator Based on Deep Neural Networks for Realistic Haptic Feedback during Teleoperated Driving,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [291]\* J. Wesker, „Vergleich von Teleoperierten Testfahrten Zwischen 4G, 5G Und Dem Menschen,“ Bachelorarbeit, Technische Universität München, Garching, 2018.

- [292]\* A. Hanuschek, „Entwicklung, Durchführung Und Validierung Eines Tests Zur Messung von Auswirkungen Optischer Und Haptischer Latenzen Auf Die Fahrzeugquerführung,“ Bachelorarbeit, Technische Universität München, Garching, 2017.
- [293]\* J. Zacharias, „Entwicklung Und Implementierung Eines Deep Learning Algorithmus Zur Erkennung von Fahrbahnmarkierungen,“ Masterarbeit, Technische Universität München, Garching, 2020.
- [294]\* C. Stadler, „Entwicklung Und Erprobung Eines Notbremsassistenten Für Das Teleoperierte Fahren Auf Basis von Lidar-Distanzmessungen,“ Masterarbeit, Technische Universität München, Garching, 2018.
- [295]\* F. Li, „Entwicklung Einer Realistischen Simulationsumgebung Für Das Teleoperierte Fahren.Pdf,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [296]\* Y. Xue, „Entwicklung einer hochgenauen Linienfolgeregelung für einen autonomen Roboter,“ Bachelorarbeit, Technische Universität München, Garching, 2019.
- [297]\* P. Rief, „Entwicklung Eines Tools Zur Einfachen Planung von Befahrbaren Pfaden Anhand Open Source Kartenmaterial,“ Semesterarbeit, Technische Universität München, Garching, 2017.
- [298]\* A. Eben, „Entwicklung einer Drohnensteuerung für das Teleoperierte Fahren,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [299]\* F. Becker, „Echtzeitimplementierung Eines Neuronalen Netzes Zur Semantischen Segmentierung von Kameradaten.Pdf,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [300]\* A. Wiedenmann, „Entwicklung Eines Deep Learning Algorithmus Zur Fahrbahnerkennung,“ Bachelorarbeit, Technische Universität München, Garching, 2017.
- [301]\* J. Schütz, „Entwicklung Einer Trajektorienfolgeregelung Für Ein Hochenergieeffizientes Elektrofahrzeug,“ Bachelorarbeit, Technische Universität München, Garching, 2018.
- [302]\* C. Roghard, „Entwicklung Und Analyse Eines Gesamtsystems Für Das Teleoperierte Fahren in Bezug Auf Technologische Und Wirtschaftliche Realisierbarkeit.“ Semesterarbeit, Technische Universität München, Garching, 2017.



# Anhang

<b>A</b>	<b>Anhang</b>	<b>xxxv</b>
<b>A.1</b>	<b>Statistik Verkehrsteilnehmer</b>	<b>xxxv</b>
A.1.1	Logistisches Mixed Effect Model	xxxv
A.1.2	Deskriptive Statistik	xxxviii
<b>A.2</b>	<b>Statistik Verkehrsschilder</b>	<b>xl</b>
A.2.1	Logistisches Mixed Effect Model	xl
A.2.2	Deskriptive Statistik	xliv
<b>A.3</b>	<b>Statistik Geschwindigkeit</b>	<b>xlvi</b>
A.3.1	Lineares Mixed Effect Model	xlvi
A.3.2	Deskriptive Statistik	li
<b>A.4</b>	<b>Statistik Spur</b>	<b>liii</b>
A.4.1	Logistisches Mixed Effect Model	liii
A.4.2	Deskriptive Statistik	lvii
<b>A.5</b>	<b>Statistik Vorhersage</b>	<b>lix</b>
A.5.1	Logistisches Mixed Effect Model	lix
A.5.2	Deskriptive Statistik	lxiii
<b>A.6</b>	<b>Statistik Usability</b>	<b>lxvi</b>
A.6.1	Lineares Mixed Effect Model	lxvi
A.6.2	Modelle	lxvii
A.6.3	Residualanalyse	lxxi
<b>A.7</b>	<b>Statistik Workload</b>	<b>lxxii</b>
A.7.1	Lineares Mixed Effect Model	lxxii
A.7.2	Deskriptive Statistik	lxxvi
<b>A.8</b>	<b>Statistik Immersion</b>	<b>lxxviii</b>
A.8.1	Linear Mixed Effect Model	lxxviii
A.8.2	Modelle Gruppen	lxxix
A.8.3	Residualanalyse	lxxxii
<b>A.9</b>	<b>Statistik Sicherheitsempfinden</b>	<b>lxxxiii</b>

A.9.1 Kummulative Link Mixed Effect Model.....	.lxxxiii
A.9.2 Deskriptive Statistik.....	.lxxxv
<b>A.10 Statistik LiDAR Abstand .....</b>	<b>.lxxxviii</b>
A.10.1 Lineares Mixed Effect Model .....	.lxxxviii
A.10.2 Deskriptive Statistik.....	.lxxxix

# A Anhang

## A.1 Statistik Verkehrsteilnehmer

### A.1.1 Logistisches Mixed Effect Model

#### M2D

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: cbind(Vt_num, Vt_ref - Vt_num) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
Data: dfM2D
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nllminb"))
```

AIC	BIC	logLik	deviance	df.resid
362.5	386.5	-174.2	348.5	223

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.7982	-0.3183	0.2636	0.5035	1.5221

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	2.00153	1.4148
Proband	(Intercept)	0.07664	0.2768

Number of obs: 230, groups: Szene, 23; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	1.7328	0.4250	4.077	4.56e-05 ***
Termin2	-0.1165	0.3513	-0.332	0.7401
Termin3	0.5303	0.3413	1.554	0.1202
Termin4	-0.5636	0.3040	-1.854	0.0638 .
QualitatN	0.1062	0.2320	0.458	0.6473

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3	Termn4
Termin2		-0.372		
Termin3		-0.345	0.430	
Termin4		-0.375	0.418	0.423
QualitatN		-0.291	0.041	0.044 -0.004

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	230	1.82	1.31	2	1.7	1.48	0	7	7	1.36	2.86	0.09

## M3D

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: cbind(Vt_num, Vt_ref - Vt_num) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
Data: dfM3D
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))
```

AIC	BIC	logLik	deviance	df.resid
426.3	449.9	-206.1	412.3	211

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.6855	-0.6790	0.4296	0.7186	1.7375

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	0.4533	0.6732
Proband	(Intercept)	0.1669	0.4086

Number of obs: 218, groups: Szene, 23; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.8728	0.2983	2.925	0.00344 **
Termin2	0.0293	0.3130	0.094	0.92542
Termin3	0.4488	0.3063	1.465	0.14282
Termin4	-0.2070	0.2833	-0.731	0.46496
QualitatN	0.2186	0.2103	1.039	0.29860

---  
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3	Termn4
Termin2	-0.453			
Termin3	-0.410	0.377		
Termin4	-0.411	0.391	0.399	
QualitatN	-0.374	0.056	0.074	0.007

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	218	1.69	1.3	1	1.55	1.48	0	7	7	1.2	1.83	0.09

## HMD

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: cbind(Vt_num, Vt_ref - Vt_num) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
Data: dfHMD
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))
```

AIC	BIC	logLik	deviance	df.resid
387.7	411.7	-186.9	373.7	222

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.1266	-0.4476	0.2983	0.5221	2.0447

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	1.892e+00	1.375e+00



Proband (Intercept) 1.704e-17 4.128e-09  
 Number of obs: 229, groups: Szene, 23; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	1.3861	0.3949	3.510	0.000447 ***
Termin2	0.1771	0.3345	0.529	0.596530
Termin3	0.4328	0.3003	1.441	0.149544
Termin4	0.4632	0.2973	1.558	0.119226
QualitatN	-0.4150	0.2164	-1.918	0.055128 .

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

(Intr) Termn2 Termn3 Termn4

Termin2 -0.359

Termin3 -0.362 0.425

Termin4 -0.347 0.392 0.439

QualitatN -0.327 0.006 0.049 0.063

optimizer (optimx) convergence code: 0 (OK)

boundary (singular) fit: see help('isSingular')

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	229	1.75	1.33	1	1.62	1.48	0	7	7	1.23	1.78	0.09

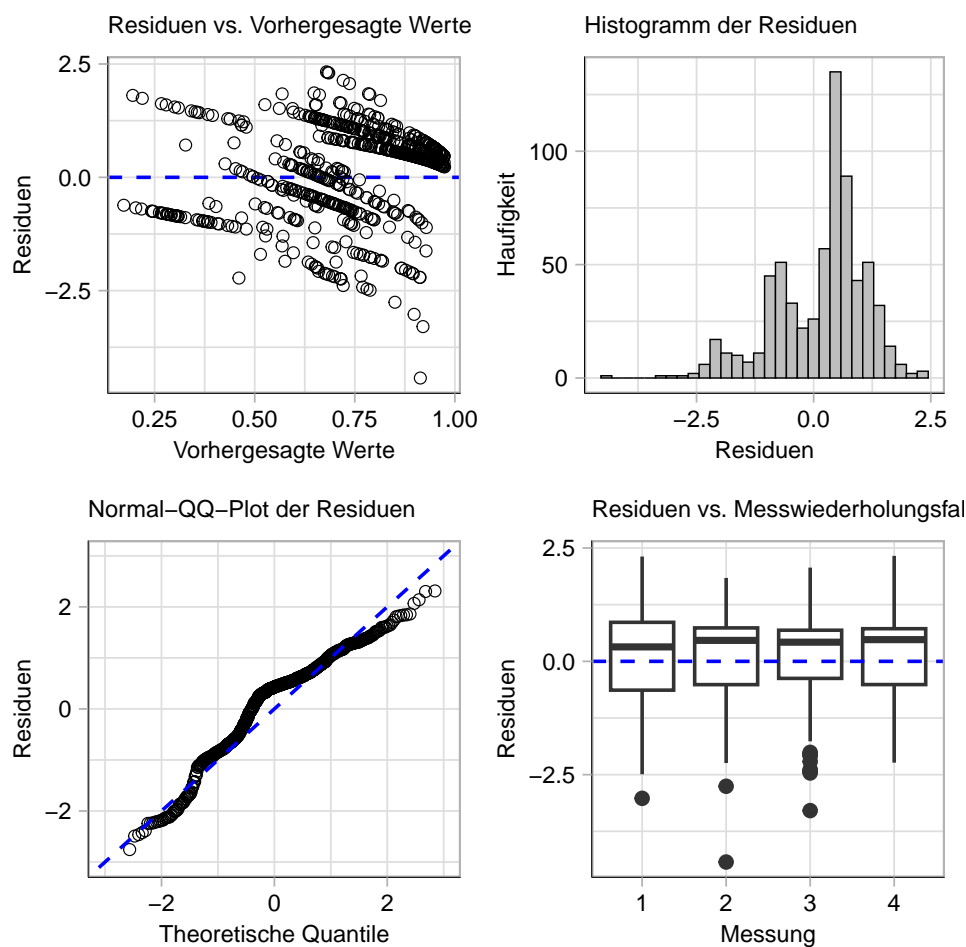


Abbildung A.1: Residuen LMM Verkehrsteilnehmer




Abbildung A.2: DHARMa Residual Analyse LMM Verkehrsteilnehmer

## A.1.2 Deskriptive Statistik

[1] "Gruppe"

Descriptive statistics by group

group: M2D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	230	77.73	33.45	100	84.66	0	0	100	100	-1.3	0.38	2.21

group: M3D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	218	71.36	36.4	100	76.45	0	0	100	100	-0.89	-0.64	2.47

group: HMD

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	229	74.06	34.71	100	79.78	0	0	100	100	-1.05	-0.23	2.29

[1] "Qualitat"

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	338	76.93	33.35	100	83.37	0	0	100	100	-1.19	0.1	1.81

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	339	71.95	36.25	100	77.26	0	0	100	100	-0.97	-0.47	1.97

[1] "Termin"

Descriptive statistics by group

group: 1

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	182	70.3	35.63	87.5	75.3	18.53	0	100	100	-0.86	-0.58	2.64

group: 2

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	164	75.12	35.69	100	81.2	0	0	100	100	-1.11	-0.21	2.79

```
group: 3
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 168 80.38 31.42   100  87.12  0  0 100  100 -1.46   0.96 2.42
```

```
-----
group: 4
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 163 72.25 36.08   100  77.68  0  0 100  100 -0.93  -0.57 2.83
```

[1] "Qualitat M2D"

Descriptive statistics by group

```
group: H
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 115 78.19 33.16   100  84.86  0  0 100  100 -1.29   0.35 3.09
```

```
-----
group: N
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 115 77.26 33.87   100  83.71  0  0 100  100 -1.29   0.35 3.16
```

[1] "Qualitat M3D"

Descriptive statistics by group

```
group: H
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 108 73.3 35.66   100  78.59  0  0 100  100 -0.92  -0.61 3.43
```

```
-----
group: N
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 110 69.45 37.18   100  74.32  0  0 100  100 -0.84  -0.72 3.54
```

[1] "Qualitat HMD"

Descriptive statistics by group

```
group: H
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 115 79.07 31.23   100  85.37  0  0 100  100 -1.33   0.67 2.91
```

```
-----
group: N
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1 114  69 37.37   100  73.54  0  0 100  100 -0.78  -0.85 3.5
```

[1] "Termin M2D"

Descriptive statistics by group

```
group: 1
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1  60 78.65 31.1   100  85.21  0  0 100  100 -1.32   0.74 4.01
```

```
-----
group: 2
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1  55 77.22 34.17   100  83.27  0  0 100  100 -1.24   0.16 4.61
```

```
-----
group: 3
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1  58 83.45 31.14   100  90.42  0  0 100  100 -1.74   1.74 4.09
```

```
-----
group: 4
  vars  n mean   sd median trimmed mad min max range skew kurtosis se
X1     1  57 71.42 36.97   100  75.98  0  0 100  100 -0.9   -0.69 4.9
```

```
[1] "Termin M3D"
```

```
Descriptive statistics by group
```

```
group: 1
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 63 65.46 37.68 71 69.1 43 0 100 100 -0.64 -1.04 4.75
```

```
-----
group: 2
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 54 72.52 37.48 100 77.64 0 0 100 100 -0.92 -0.68 5.1
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 51 80 31.12 100 86.71 0 0 100 100 -1.42 0.9 4.36
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 50 68.72 37.87 100 73.4 0 0 100 100 -0.66 -1.1 5.36
```

```
[1] "Termin HMD"
```

```
Descriptive statistics by group
```

```
group: 1
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 59 66.97 36.78 75 70.43 37.06 0 100 100 -0.68 -0.94 4.79
```

```
-----
group: 2
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 55 75.56 35.87 100 81.24 0 0 100 100 -1.12 -0.22 4.84
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 59 77.68 32.22 100 83.33 0 0 100 100 -1.19 0.24 4.19
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 56 76.23 33.71 100 81.93 0 0 100 100 -1.19 0.11 4.5
```

## A.2 Statistik Verkehrsschilder

### A.2.1 Logistisches Mixed Effect Model

```
[1] "AIC"
```

```
[1] 456.0066
```

```
[1] "BIC"
```

```
[1] 497.0559
```

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
```

```
Family: binomial ( logit )
```

```
Formula: cbind(Vs_num, Vs_ref - Vs_num) ~ Gruppe + Termin + Qualitat +  
(1 | Proband) + (1 | Szene)
```

```
Data: df
```

```
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nllminb"))
```

```

      AIC      BIC   logLik deviance df.resid
1456.0    1497.1   -219.0   438.0     698

Scaled residuals:
  Min       1Q   Median       3Q      Max
-1.774  0.000  0.000  0.000  1.804

Random effects:
 Groups Name          Variance Std.Dev.
 Proband (Intercept) 0.07245  0.2692
 Szene (Intercept)  0.09650  0.3106
Number of obs: 707, groups: Proband, 30; Szene, 24

Fixed effects:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)  0.03537    0.30842   0.115   0.909
GruppeM3D    -0.38062    0.28799  -1.322   0.186
GruppeHMD    -0.00234    0.28272  -0.008   0.993
Termin2       0.00401    0.32309   0.012   0.990
Termin3      -0.13838    0.30075  -0.460   0.645
Termin4       0.64860    0.30077   2.156   0.031 *
QualitatN    -0.27084    0.21991  -1.232   0.218
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:
      (Intr) GrpM3D GrpHMD Termn2 Termn3 Termn4
GruppeM3D -0.456
GruppeHMD -0.468  0.491
Termin2   -0.438  0.012  0.003
Termin3   -0.528 -0.009  0.020  0.453
Termin4   -0.442  0.026  0.009  0.471  0.468
QualitatN -0.354 -0.001  0.002 -0.024  0.139 -0.120

```

## M2D

```

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: cbind(Vs_num, Vs_ref - Vs_num) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
Data: dfM2D
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

```

```

      AIC      BIC   logLik deviance df.resid
159.4    183.7   -72.7   145.4     233

Scaled residuals:
  Min       1Q   Median       3Q      Max
-1.545  0.000  0.000  0.000  1.407

Random effects:
 Groups Name          Variance Std.Dev.
 Szene (Intercept)  0.0000  0.0000
 Proband (Intercept) 0.2793  0.5285
Number of obs: 240, groups: Szene, 24; Proband, 10

Fixed effects:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)  0.03255    0.43917   0.074   0.941

```

```
Termin2      0.47010    0.55827    0.842    0.400
Termin3     -0.06413    0.51426   -0.125    0.901
Termin4      0.68714    0.51845    1.325    0.185
QualitatN   -0.46278    0.38525   -1.201    0.230
```

Correlation of Fixed Effects:

```
(Intr) Termn2 Termn3 Termn4
```

```
Termin2     -0.517
Termin3     -0.632  0.447
Termin4     -0.528  0.464  0.499
QualitatN  -0.403 -0.048  0.087 -0.165
```

```
optimizer (optimx) convergence code: 0 (OK)
boundary (singular) fit: see help('isSingular')
```

```
vars  n mean  sd median trimmed mad min max range skew kurtosis  se
X1    1 240 0.28 0.5      0    0.19  0  0  2    2 1.55    1.49 0.03
```

### M3D

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) [`'glmerMod'`]

Family: binomial (logit)

Formula: `cbind(Vs_num, Vs_ref - Vs_num) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)`

Data: `dfM3D`

Control: `glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))`

```
AIC      BIC    logLik deviance df.resid
152      176     -69     138     221
```

Scaled residuals:

```
Min      1Q Median      3Q      Max
-1.076  0.000  0.000  0.000  1.939
```

Random effects:

```
Groups Name          Variance Std.Dev.
Szene  (Intercept)  0.000e+00 0.000e+00
Proband (Intercept) 9.077e-12 3.013e-06
```

Number of obs: 228, groups: Szene, 24; Proband, 10

Fixed effects:

```
Estimate Std. Error z value Pr(>|z|)
(Intercept) -0.302138  0.403181  -0.749  0.454
Termin2     -0.322912  0.562218  -0.574  0.566
Termin3     -0.275582  0.490201  -0.562  0.574
Termin4      0.449288  0.519645   0.865  0.387
QualitatN   -0.006298  0.381034  -0.017  0.987
```

Correlation of Fixed Effects:

```
(Intr) Termn2 Termn3 Termn4
```

```
Termin2     -0.531
Termin3     -0.697  0.445
Termin4     -0.546  0.428  0.474
QualitatN  -0.487 -0.034  0.141 -0.094
```

```
optimizer (optimx) convergence code: 0 (OK)
```

```
boundary (singular) fit: see help('isSingular')
```

Parameters or bounds appear to have different scalings.

This can cause poor performance in optimization.

It is important for derivative free methods like BOBYQA, UOBYQA, NEWUOA.

```
vars  n mean  sd median trimmed mad min max range skew kurtosis  se
```

```
X1    1 228 0.22 0.46      0   0.14  0  0  2    2 1.85    2.58 0.03
```

## HMD

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']

Family: binomial ( logit )

Formula: cbind(Vs\_num, Vs\_ref - Vs\_num) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)

Data: dfHMD

Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

AIC	BIC	logLik	deviance	df.resid
165.9	190.2	-75.9	151.9	232

Scaled residuals:

Min	1Q	Median	3Q	Max
-1.825	0.000	0.000	0.000	1.533

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	0	0
Proband	(Intercept)	0	0

Number of obs: 239, groups: Szene, 24; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-0.02911	0.38827	-0.075	0.9402
Termin2	-0.13219	0.52351	-0.253	0.8006
Termin3	0.11620	0.49649	0.234	0.8150
Termin4	0.81854	0.48701	1.681	0.0928
QualitatN	-0.27914	0.36832	-0.758	0.4485

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3	Termn4
Termin2	-0.562			
Termin3	-0.671	0.443		
Termin4	-0.563	0.455	0.464	
QualitatN	-0.482	-0.014	0.147	-0.101

optimizer (optimx) convergence code: 0 (OK)

boundary (singular) fit: see help('isSingular')

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	239	0.28	0.51	0	0.19	0	0	2	2	1.61	1.69	0.03




Abbildung A.3: DHARMA Residual Analyse LMM Verkehrsschilder

## A.2.2 Deskriptive Statistik

[1] "Gruppe"

Descriptive statistics by group

group: M2D

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	240	76.04	40.12	100	82.55	0	0	100	100	-1.2	-0.37	2.59

group: M3D

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	228	69.96	43.61	100	74.73	0	0	100	100	-0.86	-1.13	2.89

group: HMD

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	239	73.85	41.96	100	79.53	0	0	100	100	-1.07	-0.72	2.71

[1] 0.8050847

[1] "Qualitat"

Descriptive statistics by group

group: H

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	353	74.22	41.3	100	80.21	0	0	100	100	-1.1	-0.64	2.2

group: N

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	354	72.46	42.55	100	77.99	0	0	100	100	-1	-0.88	2.26

[1] "Termin"

Descriptive statistics by group

group: 1

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	188	69.15	43.94	100	73.68	0	0	100	100	-0.82	-1.21	3.2

group: 2

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
------	---	------	----	--------	---------	-----	-----	-----	-------	------	----------	----



```
X1 1 172 77.62 40.56 100 84.42 0 0 100 100 -1.31 -0.19 3.09
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 177 68.93 43.89 100 73.43 0 0 100 100 -0.81 -1.22 3.3
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 170 78.24 38.03 100 85.29 0 0 100 100 -1.34 0.06 2.92
```

```
[1] "Qualitat M2D"
```

```
Descriptive statistics by group
```

```
group: H
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 120 78.75 38.16 100 85.94 0 0 100 100 -1.38 0.12 3.48
```

```
-----
group: N
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 120 73.33 41.98 100 79.17 0 0 100 100 -1.04 -0.78 3.83
```

```
[1] "Qualitat M3D"
```

```
Descriptive statistics by group
```

```
group: H
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 113 69.91 44.09 100 74.73 0 0 100 100 -0.85 -1.17 4.15
```

```
-----
group: N
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 115 70 43.33 100 74.73 0 0 100 100 -0.86 -1.13 4.04
```

```
[1] "Qualitat HMD"
```

```
Descriptive statistics by group
```

```
group: H
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 120 73.75 41.49 100 79.69 0 0 100 100 -1.06 -0.72 3.79
```

```
-----
group: N
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 119 73.95 42.61 100 79.38 0 0 100 100 -1.08 -0.76 3.91
```

```
[1] "Termin M2D"
```

```
Descriptive statistics by group
```

```
group: 1
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 62 72.58 43.11 100 78 0 0 100 100 -0.99 -0.94 5.48
```

```
-----
group: 2
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 58 81.03 38.42 100 87.5 0 0 100 100 -1.54 0.47 5.04
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 61 71.31 42.29 100 76.53 0 0 100 100 -0.91 -1 5.41
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 59 79.66 36.1 100 85.71 0 0 100 100 -1.4 0.35 4.7
```

[1] "Termin M3D"

Descriptive statistics by group

group: 1

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 65 70.77 42.29 100 75.47 0 0 100 100 -0.88 -1.04 5.25
```

-----  
group: 2

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 56 75 42.64 100 80.43 0 0 100 100 -1.12 -0.69 5.7
```

-----  
group: 3

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 55 60 47.53 100 62.22 0 0 100 100 -0.4 -1.79 6.41
```

-----  
group: 4

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 52 74.04 41.41 100 79.76 0 0 100 100 -1.06 -0.72 5.74
```

[1] "Termin HMD"

Descriptive statistics by group

group: 1

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 61 63.93 46.66 100 67.35 0 0 100 100 -0.56 -1.63 5.97
```

-----  
group: 2

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 58 76.72 41.06 100 82.29 0 0 100 100 -1.23 -0.39 5.39
```

-----  
group: 3

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 61 74.59 41.46 100 80.61 0 0 100 100 -1.1 -0.66 5.31
```

-----  
group: 4

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 59 80.51 37.16 100 86.73 0 0 100 100 -1.49 0.46 4.84
```

## A.3 Statistik Geschwindigkeit

### A.3.1 Lineares Mixed Effect Model

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']  
 Formula: Speed\_log ~ Gruppe \* Termin + Gruppe \* Qualitat + (1 | Proband) + (1 | Szene)  
 Data: dff

REML criterion at convergence: -593.5

Scaled residuals:

```
Min 1Q Median 3Q Max
-3.8792 -0.5674 0.0162 0.5430 2.7177
```

Random effects:

```
Groups Name Variance Std.Dev.
```

```

Proband (Intercept) 0.002172 0.04660
Szene (Intercept) 0.006771 0.08229
Residual 0.014158 0.11899
Number of obs: 530, groups: Proband, 30; Szene, 18

```

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	-0.617125	0.031896	78.927042	-19.348	< 2e-16 ***
GruppeM3D	0.036165	0.035327	110.688209	1.024	0.30819
GruppeHMD	0.037919	0.035898	117.004163	1.056	0.29301
Termin2	0.021924	0.025950	479.708648	0.845	0.39860
Termin3	0.020445	0.025082	477.429300	0.815	0.41540
Termin4	0.021401	0.026210	480.874456	0.817	0.41461
QualitatN	-0.026566	0.017875	471.556418	-1.486	0.13789
GruppeM3D:Termin2	-0.058307	0.035556	476.058047	-1.640	0.10170
GruppeHMD:Termin2	-0.034654	0.036241	476.094604	-0.956	0.33946
GruppeM3D:Termin3	-0.028834	0.035782	480.781748	-0.806	0.42073
GruppeHMD:Termin3	-0.031683	0.035235	475.747600	-0.899	0.36901
GruppeM3D:Termin4	-0.109786	0.037346	483.491903	-2.940	0.00344 **
GruppeHMD:Termin4	-0.029287	0.036652	479.089856	-0.799	0.42465
GruppeM3D:QualitatN	0.044601	0.025631	471.639355	1.740	0.08248 .
GruppeHMD:QualitatN	0.005361	0.025347	471.605997	0.211	0.83259

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']  
Formula: Speed\_log ~ Gruppe + Termin + Qualitat + (1 | Proband) + (1 | Szene)  
Data: dff

REML criterion at convergence: -621.6

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.6509	-0.5582	0.0091	0.6095	2.4324

Random effects:

Groups	Name	Variance	Std.Dev.
Proband	(Intercept)	0.002061	0.04540
Szene	(Intercept)	0.006775	0.08231
Residual		0.014366	0.11986

Number of obs: 530, groups: Proband, 30; Szene, 18

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	-6.018e-01	2.806e-02	4.879e+01	-21.447	<2e-16 ***
GruppeM3D	1.265e-02	2.406e-02	2.745e+01	0.526	0.603
GruppeHMD	1.698e-02	2.392e-02	2.698e+01	0.710	0.484
Termin2	-8.715e-03	1.588e-02	4.943e+02	-0.549	0.583
Termin3	-1.495e-04	1.516e-02	4.923e+02	-0.010	0.992
Termin4	-2.166e-02	1.584e-02	4.960e+02	-1.367	0.172
QualitatN	-1.133e-02	1.050e-02	4.796e+02	-1.079	0.281

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	GrpM3D	GrpHMD	Termn2	Termn3	Termn4
GruppeM3D	-0.429					
GruppeHMD	-0.424	0.497				
Termin2	-0.284	0.001	0.000			
Termin3	-0.303	0.021	-0.005	0.507		

```
Termin4    -0.273  0.017 -0.007  0.486  0.497
QualitatN  -0.213  0.000  0.001  0.045  0.118  0.023
```

### M2D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']  
Formula: Speed\_log ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)  
Data: dffM2D

REML criterion at convergence: -224.5

Scaled residuals:

```
      Min      1Q  Median      3Q      Max
-3.2875 -0.5842  0.0257  0.5138  3.1567
```

Random effects:

```
Groups   Name          Variance Std.Dev.
Szene    (Intercept)  0.0047376 0.06883
Proband  (Intercept)  0.0003806 0.01951
Residual                   0.0122177 0.11053
```

Number of obs: 180, groups: Szene, 18; Proband, 10

Fixed effects:

```
              Estimate Std. Error      df t value Pr(>|t|)
(Intercept)  -0.61577    0.02605  54.31164 -23.642 <2e-16 ***
Termin2       0.02220    0.02489 161.57636  0.892  0.374
Termin3       0.02137    0.02370 157.24422  0.902  0.369
Termin4       0.01323    0.02467 159.41573  0.536  0.592
QualitatN    -0.02620    0.01661 149.06980 -1.577  0.117
```

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

```
          (Intr) Termn2 Termn3 Termn4
Termin2   -0.485
Termin3   -0.514  0.522
Termin4   -0.459  0.490  0.494
QualitatN -0.364  0.050  0.118  0.021
```

### M3D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']  
Formula: Speed\_log ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)  
Data: dffM3D

REML criterion at convergence: -157.3

Scaled residuals:

```
      Min      1Q  Median      3Q      Max
-3.7935 -0.5860 -0.0954  0.5767  2.1527
```

Random effects:

```
Groups   Name          Variance Std.Dev.
Szene    (Intercept)  0.007130 0.08444
Proband  (Intercept)  0.005668 0.07529
Residual                   0.015379 0.12401
```

Number of obs: 171, groups: Szene, 18; Proband, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	-0.57613	0.03792	32.86409	-15.192	< 2e-16 ***
Termin2	-0.04261	0.02879	153.34660	-1.480	0.14095
Termin3	-0.01502	0.02874	152.09804	-0.523	0.60205
Termin4	-0.09974	0.02990	151.52355	-3.336	0.00107 **
QualitatN	0.01868	0.01917	140.59147	0.974	0.33158

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3	Termn4
Termin2	-0.372			
Termin3	-0.369	0.457		
Termin4	-0.333	0.471	0.474	
QualitatN	-0.273	0.033	0.092	-0.032

## HMD

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Speed\_log ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)

Data: dffHMD

REML criterion at convergence: -185.9

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.2606	-0.4421	0.0251	0.4548	2.3489

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	0.0087486	0.09353
Proband	(Intercept)	0.0005553	0.02356
Residual		0.0145478	0.12061

Number of obs: 179, groups: Szene, 18; Proband, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	-0.580147	0.031907	46.879026	-18.183	<2e-16 ***
Termin2	-0.013948	0.027725	157.375735	-0.503	0.616
Termin3	-0.011700	0.026140	154.486303	-0.448	0.655
Termin4	-0.002298	0.027166	157.364434	-0.085	0.933
QualitatN	-0.021631	0.018230	148.429698	-1.187	0.237

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3	Termn4
Termin2	-0.439			
Termin3	-0.483	0.525		
Termin4	-0.445	0.492	0.520	
QualitatN	-0.342	0.050	0.142	0.076

summary statistics

-----

min: -20 max: 39

median: 4

mean: 5.266038

estimated sd: 8.567037

estimated skewness: 0.8528075

estimated kurtosis: 4.547665

Cullen and Frey graph




Abbildung A.4: Analyse der Verteilung




Abbildung A.5: DHARMA Residual Analyse LMM Geschwindigkeit gm0

## A.3.2 Deskriptive Statistik

### Gruppe

Descriptive statistics by group

group: M2D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	240	3.41	6.54	2	2.86	4.45	-15	34	49	1.13	2.58	0.42

group: M3D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	228	4.22	8.69	2	3.24	4.45	-20	39	59	1.24	2.27	0.58

group: HMD

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	239	4.23	7.95	2	3.34	4.45	-15	39	54	1.29	2.51	0.51

### Qualitat

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	265	5.59	8.4	5	4.92	7.41	-15	39	54	0.91	1.49	0.52

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	265	4.94	8.73	3	4.32	7.41	-20	39	59	0.8	1.48	0.54

[1] "M2D"

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	90	5.28	6.92	5	5.19	7.41	-15	28	43	0.19	0.7	0.73

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	90	3.81	7.45	2.5	3.14	6.67	-8	34	42	1.13	2.32	0.79

[1] "M2D"

```
Descriptive statistics by group
group: H
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  85 5.26 9.31      4    4.22 7.41 -10  33   43 1.08    0.97 1.01
-----
group: N
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  86 5.99 9.98     4.5   5.53 8.15 -20  39   59 0.55    1.03 1.08
```

[1] "HMD"

```
Descriptive statistics by group
group: H
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  90 6.21 8.89      5    5.54 7.41 -10  39   49 0.96    1.55 0.94
-----
group: N
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  89 5.08 8.61      3    4.55 5.93 -15  34   49 0.7     0.85 0.91
```

## Termin

```
Descriptive statistics by group
group: 1
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1 138 6.59 9.71     3.5   5.46 8.15 -10  39   49 1.09    0.9 0.83
-----
group: 2
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1 131 4.42 7.61      5    4.08 7.41 -15  34   49 0.57    1.33 0.66
-----
group: 3
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1 141 5.74 9.17      4    5.23 7.41 -20  39   59 0.6     1.12 0.77
-----
group: 4
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1 120 4.12 7.15     4.5   3.86 5.19 -13  28   41 0.44    0.78 0.65
```

[1] "M2D"

```
Descriptive statistics by group
group: 1
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  46 4.67 8.32      2    3.79 7.41  -8  34   42 1.2     1.77 1.23
-----
group: 2
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  44 4.2  6.77     2.5   3.75 6.67  -8  24   32 0.68    0.51 1.02
-----
group: 3
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  49 5.04 7.53      5    4.95 7.41 -15  28   43 0.2     1.09 1.08
-----
group: 4
  vars  n mean  sd median trimmed  mad min max range skew kurtosis  se
X1     1  41 4.17 6.08      5    4.27 5.93  -8  16   24 -0.05   -0.7 0.95
```



```
[1] "M3D"
```

```
Descriptive statistics by group
```

```
group: 1
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 48 8.42 10.43 5 7.57 9.64 -10 39 49 0.83 0.34 1.5
```

```
-----
group: 2
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 45 4.33 7.55 4 3.65 7.41 -8 34 42 1.37 3.46 1.13
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 42 6.5 10.6 4 6.15 8.9 -20 33 53 0.29 0.11 1.64
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 36 2.5 8.8 1.5 1.87 7.41 -13 28 41 0.7 0.71 1.47
```

```
[1] "HMD"
```

```
Descriptive statistics by group
```

```
group: 1
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 44 6.59 10.08 3.5 5.36 7.41 -6 34 40 1.12 0.49 1.52
```

```
-----
group: 2
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 42 4.74 8.6 5 4.85 8.15 -15 24 39 -0.14 -0.18 1.33
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 50 5.78 9.47 4 5.07 7.41 -10 39 49 0.96 1.35 1.34
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 43 5.42 6.42 5 4.94 4.45 -8 24 32 0.76 0.59 0.98
```

## A.4 Statistik Spur

### A.4.1 Logistisches Mixed Effect Model

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
```

```
Family: binomial ( logit )
```

```
Formula: cbind(Spur_cor, Spur_fal) ~ Gruppe * Termin + Gruppe * Qualitat +
(1 | Proband) + (1 | Szene)
```

```
Data: df
```

```
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlnminb"))
```

```
AIC      BIC    logLik deviance df.resid
894.2    971.7   -430.1   860.2     690
```

```
Scaled residuals:
```

```
Min      1Q  Median      3Q      Max
-2.3759 -0.7462  0.4074  0.6974  2.7201
```

```
Random effects:
```

## A Anhang

```
Groups Name      Variance Std.Dev.
Proband (Intercept) 0.2525  0.5025
Szene  (Intercept) 1.2031  1.0969
Number of obs: 707, groups: Proband, 30; Szene, 24
```

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.70040	0.44133	1.587	0.1125
GruppeM3D	0.11528	0.53619	0.215	0.8298
GruppeHMD	-0.66571	0.52834	-1.260	0.2077
Termin2	-1.00810	0.42922	-2.349	0.0188 *
Termin3	-0.19621	0.42588	-0.461	0.6450
Termin4	0.01852	0.42599	0.043	0.9653
QualitatN	-0.23798	0.30056	-0.792	0.4285
GruppeM3D:Termin2	0.55408	0.59648	0.929	0.3529
GruppeHMD:Termin2	1.19527	0.59184	2.020	0.0434 *
GruppeM3D:Termin3	0.02941	0.60514	0.049	0.9612
GruppeHMD:Termin3	0.44292	0.59023	0.750	0.4530
GruppeM3D:Termin4	-1.02577	0.60901	-1.684	0.0921 .
GruppeHMD:Termin4	-0.14428	0.59086	-0.244	0.8071
GruppeM3D:QualitatN	-0.41535	0.43273	-0.960	0.3371
GruppeHMD:QualitatN	0.16261	0.42109	0.386	0.6994

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']

Family: binomial ( logit )

Formula: cbind(Spur\_cor, Spur\_fal) ~ Gruppe + Termin + Qualitat + (1 | Proband) + (1 | Szene)

Data: df

Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlnminb"))

AIC	BIC	logLik	deviance	df.resid
890.4	931.4	-436.2	872.4	698

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.6746	-0.7807	0.4149	0.7198	2.8418

Random effects:

```
Groups Name      Variance Std.Dev.
Proband (Intercept) 0.2296  0.4792
Szene  (Intercept) 1.1657  1.0797
Number of obs: 707, groups: Proband, 30; Szene, 24
```

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.62505	0.35587	1.756	0.0790 .
GruppeM3D	-0.18558	0.30051	-0.618	0.5369
GruppeHMD	-0.21110	0.29789	-0.709	0.4785
Termin2	-0.40707	0.25404	-1.602	0.1091
Termin3	-0.02176	0.24918	-0.087	0.9304
Termin4	-0.33698	0.24915	-1.352	0.1762
QualitatN	-0.30140	0.17314	-1.741	0.0817 .

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	GrpM3D	GrpHMD	Termn2	Termn3	Termn4
GruppeM3D		-0.424				
GruppeHMD		-0.424	0.497			

liv

```

Termin2   -0.371  0.011  0.006
Termin3   -0.370  0.016  0.000  0.492
Termin4   -0.354  0.023  0.008  0.492  0.481
QualitatN -0.291  0.000  0.007  0.100  0.116  0.031

```

## M2D

```

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: cbind(Spur_cor, Spur_fal) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
Data: dfM2D
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

```

```

      AIC      BIC  logLik deviance df.resid
313.4    337.8  -149.7   299.4     233

```

Scaled residuals:

```

      Min      1Q  Median      3Q      Max
-2.0720 -0.7342  0.4268  0.6936  2.1760

```

Random effects:

```

Groups Name      Variance Std.Dev.
Szene  (Intercept) 1.384    1.1763
Proband (Intercept) 0.150    0.3873
Number of obs: 240, groups:  Szene, 24; Proband, 10

```

Fixed effects:

```

              Estimate Std. Error z value Pr(>|z|)
(Intercept)   0.7673    0.4478   1.713  0.0866 .
Termin2       -1.1278    0.4567  -2.469  0.0135 *
Termin3       -0.2801    0.4340  -0.645  0.5187
Termin4       -0.0288    0.4361  -0.066  0.9473
QualitatN     -0.2240    0.3027  -0.740  0.4591
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Correlation of Fixed Effects:

```

              (Intr) Termn2 Termn3 Termn4
Termin2     -0.544
Termin3     -0.537  0.519
Termin4     -0.489  0.488  0.488
QualitatN  -0.408  0.126  0.132  0.032

```

## M3D

```

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: cbind(Spur_cor, Spur_fal) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
Data: dfM3D
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

```

```

      AIC      BIC  logLik deviance df.resid
294.2    318.2  -140.1   280.2     221

```

Scaled residuals:

```

      Min      1Q  Median      3Q      Max
-2.2357 -0.6792  0.3047  0.6725  2.0599

```

## A Anhang

---

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	1.5091	1.2285
Proband	(Intercept)	0.5233	0.7234

Number of obs: 228, groups: Szene, 24; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.9161	0.5097	1.798	0.0723 .
Termin2	-0.4273	0.4768	-0.896	0.3701
Termin3	-0.3053	0.4718	-0.647	0.5176
Termin4	-1.0905	0.4783	-2.280	0.0226 *
QualitatN	-0.7425	0.3317	-2.238	0.0252 *

---  
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termin2	Termin3	Termin4
Termin2	-0.482			
Termin3	-0.483	0.466		
Termin4	-0.454	0.474	0.476	
QualitatN	-0.431	0.145	0.180	0.099

## HMD

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']

Family: binomial ( logit )

Formula: cbind(Spur\_cor, Spur\_fal) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)

Data: dfHMD

Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

AIC	BIC	logLik	deviance	df.resid
332.6	356.9	-159.3	318.6	232

Scaled residuals:

Min	1Q	Median	3Q	Max
-1.5889	-0.8214	0.5073	0.8049	1.6656

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	0.6353	0.7970
Proband	(Intercept)	0.1434	0.3786

Number of obs: 239, groups: Szene, 24; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.05134	0.38431	0.134	0.894
Termin2	0.22028	0.41447	0.531	0.595
Termin3	0.22852	0.40458	0.565	0.572
Termin4	-0.08281	0.40617	-0.204	0.838
QualitatN	-0.06157	0.28323	-0.217	0.828

Correlation of Fixed Effects:

	(Intr)	Termin2	Termin3	Termin4
Termin2	-0.544			
Termin3	-0.567	0.499		
Termin4	-0.537	0.488	0.492	
QualitatN	-0.425	0.061	0.113	0.044




Abbildung A.6: DHARMA Residual Analyse LMM Spur

## A.4.2 Deskriptive Statistik

### Gruppe

Descriptive statistics by group

group: M2D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	240	56.25	49.71	100	57.81	0	0	100	100	-0.25	-1.95	3.21

group: M3D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	228	51.75	50.08	100	52.17	0	0	100	100	-0.07	-2	3.32

group: HMD

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	239	52.3	50.05	100	52.85	0	0	100	100	-0.09	-2	3.24

### Qualitat

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	353	56.09	49.7	100	57.6	0	0	100	100	-0.24	-1.95	2.65

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	354	50.85	50.06	100	51.06	0	0	100	100	-0.03	-2	2.66

[1] "M2D"

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	120	57.5	49.64	100	59.38	0	0	100	100	-0.3	-1.93	4.53

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	120	55	49.96	100	56.25	0	0	100	100	-0.2	-1.98	4.56

[1] "M3D"

```
Descriptive statistics by group
group: H
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 113 57.52 49.65   100  59.34  0  0 100   100 -0.3   -1.93 4.67
-----
group: N
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 115 46.09 50.06    0  45.16  0  0 100   100 0.15   -1.99 4.67
```

[1] "HMD"

```
Descriptive statistics by group
group: H
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 120 53.33 50.1   100  54.17  0  0 100   100 -0.13   -2 4.57
-----
group: N
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 119 51.26 50.2   100  51.55  0  0 100   100 -0.05   -2.01 4.6
```

## Termin

```
Descriptive statistics by group
group: 1
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 188 55.32 49.85   100  56.58  0  0 100   100 -0.21   -1.97 3.64
-----
group: 2
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 172 51.74 50.12   100  52.17  0  0 100   100 -0.07   -2.01 3.82
-----
group: 3
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 177 55.93 49.79   100  57.34  0  0 100   100 -0.24   -1.95 3.74
-----
group: 4
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1 170 50.59 50.14   100  50.74  0  0 100   100 -0.02   -2.01 3.85
```

[1] "M2D"

```
Descriptive statistics by group
group: 1
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1  62 59.68 49.45   100    62  0  0 100   100 -0.39   -1.88 6.28
-----
group: 2
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1  58 44.83 50.17    0  43.75  0  0 100   100 0.2   -1.99 6.59
-----
group: 3
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1  61 57.38 49.86   100  59.18  0  0 100   100 -0.29   -1.95 6.38
-----
group: 4
  vars  n mean   sd median trimmed mad min max range skew kurtosis  se
X1     1  59 62.71 48.77   100  65.31  0  0 100   100 -0.51   -1.77 6.35
```

```
[1] "M3D"
```

```
Descriptive statistics by group
```

```
group: 1
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 65 56.92 49.9 100 58.49 0 0 100 100 -0.27 -1.95 6.19
```

```
-----
group: 2
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 56 53.57 50.32 100 54.35 0 0 100 100 -0.14 -2.02 6.72
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 55 56.36 50.05 100 57.78 0 0 100 100 -0.25 -1.97 6.75
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 52 38.46 49.13 0 35.71 0 0 100 100 0.46 -1.82 6.81
```

```
[1] "HMD"
```

```
Descriptive statistics by group
```

```
group: 1
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 61 49.18 50.41 0 48.98 0 0 100 100 0.03 -2.03 6.45
```

```
-----
group: 2
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 58 56.9 49.95 100 58.33 0 0 100 100 -0.27 -1.96 6.56
```

```
-----
group: 3
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 61 54.1 50.25 100 55.1 0 0 100 100 -0.16 -2.01 6.43
```

```
-----
group: 4
```

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 59 49.15 50.42 0 48.98 0 0 100 100 0.03 -2.03 6.56
```

## A.5 Statistik Vorhersage

### A.5.1 Logistisches Mixed Effect Model

```
[1] "AIC"
```

```
[1] 883.554
```

```
[1] "BIC"
```

```
[1] 961.0915
```

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
```

```
Family: binomial ( logit )
```

```
Formula: cbind(Sa_level_32, 1 - Sa_level_32) ~ Gruppe * Termin + Gruppe *
Qualitat + (1 | Proband) + (1 | Szene)
```

```
Data: df
```

```
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nllminb"))
```

## A Anhang

---

```
      AIC      BIC  logLik deviance df.resid
883.6    961.1   -424.8   849.6     690

Scaled residuals:
  Min      1Q  Median      3Q      Max
-3.0530 -0.8643  0.4133  0.7194  2.3915

Random effects:
 Groups Name      Variance Std.Dev.
 Proband (Intercept) 0.1675   0.4092
 Szene (Intercept)  0.9600   0.9798
Number of obs: 707, groups: Proband, 30; Szene, 24

Fixed effects:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)    0.70633   0.41758   1.691  0.0907 .
GruppeM3D      0.29124   0.51314   0.568  0.5703
GruppeHMD     -0.03238   0.51076  -0.063  0.9495
Termin2       -0.09393   0.42202  -0.223  0.8239
Termin3        0.60646   0.43075   1.408  0.1592
Termin4        0.45953   0.42463   1.082  0.2792
QualitatN     -0.19227   0.30309  -0.634  0.5258
GruppeM3D:Termin2 -0.19970   0.58644  -0.341  0.7335
GruppeHMD:Termin2 -0.01102   0.58287  -0.019  0.9849
GruppeM3D:Termin3 -0.67980   0.60784  -1.118  0.2634
GruppeHMD:Termin3 -1.12953   0.59109  -1.911  0.0560 .
GruppeM3D:Termin4 -1.07682   0.59749  -1.802  0.0715 .
GruppeHMD:Termin4  0.23935   0.60017   0.399  0.6900
GruppeM3D:QualitatN -0.19350   0.43049  -0.449  0.6531
GruppeHMD:QualitatN -0.33903   0.42460  -0.798  0.4246
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

[1] "AIC"

[1] 880.5116

[1] "BIC"

[1] 921.5609

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: cbind(Sa_level_32, 1 - Sa_level_32) ~ Gruppe + Termin + Qualitat +
  (1 | Proband) + (1 | Szene)
Data: df
Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

      AIC      BIC  logLik deviance df.resid
880.5    921.6   -431.3   862.5     698

Scaled residuals:
  Min      1Q  Median      3Q      Max
-2.8635 -0.8733  0.4308  0.7299  2.0708

Random effects:
 Groups Name      Variance Std.Dev.
 Proband (Intercept) 0.1517   0.3894
 Szene (Intercept)  0.9432   0.9712
```



Number of obs: 707, groups: Proband, 30; Szene, 24

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	1.02982	0.33494	3.075	0.00211 **
GruppeM3D	-0.26533	0.27450	-0.967	0.33374
GruppeHMD	-0.44022	0.27098	-1.625	0.10426
Termin2	-0.16748	0.25183	-0.665	0.50601
Termin3	-0.02842	0.24591	-0.116	0.90800
Termin4	0.19065	0.24875	0.766	0.44342
QualitatN	-0.37144	0.17269	-2.151	0.03148 *

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	GrpM3D	GrpHMD	Termn2	Termn3	Termn4
GruppeM3D	-0.425					
GruppeHMD	-0.418	0.504				
Termin2	-0.392	0.013	0.001			
Termin3	-0.404	0.030	-0.001	0.492		
Termin4	-0.366	0.025	-0.002	0.470	0.469	
QualitatN	-0.329	0.008	0.008	0.100	0.147	0.050

## M2D

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']

Family: binomial ( logit )

Formula: cbind(Sa\_level\_32, 1 - Sa\_level\_32) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)

Data: dfM2D

Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

AIC	BIC	logLik	deviance	df.resid
296.7	321.1	-141.3	282.7	233

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.7221	-0.8298	0.3896	0.6405	2.0532

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	1.2896	1.1356
Proband	(Intercept)	0.2914	0.5398

Number of obs: 240, groups: Szene, 24; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.73526	0.46168	1.593	0.111
Termin2	-0.09219	0.44668	-0.206	0.836
Termin3	0.66497	0.44842	1.483	0.138
Termin4	0.54011	0.44789	1.206	0.228
QualitatN	-0.21588	0.31223	-0.691	0.489

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3	Termn4
Termin2	-0.506			
Termin3	-0.483	0.483		
Termin4	-0.432	0.459	0.454	
QualitatN	-0.410	0.100	0.119	0.009

## M3D

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']

Family: binomial ( logit )

Formula: cbind(Sa\_level\_32, 1 - Sa\_level\_32) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)

Data: dfM3D

Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

AIC	BIC	logLik	deviance	df.resid
301.4	325.4	-143.7	287.4	221

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.2198	-0.8655	0.4738	0.6777	1.5244

Random effects:

Groups	Name	Variance	Std.Dev.
--------	------	----------	----------

Szene	(Intercept)	0.8250	0.9083
-------	-------------	--------	--------

Proband	(Intercept)	0.1711	0.4136
---------	-------------	--------	--------

Number of obs: 228, groups: Szene, 24; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.95480	0.42221	2.261	0.0237 *
Termin2	-0.29503	0.44283	-0.666	0.5053
Termin3	0.03498	0.44428	0.079	0.9372
Termin4	-0.53658	0.43902	-1.222	0.2216
QualitatN	-0.40635	0.30615	-1.327	0.1844

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termin2	Termin3	Termin4
Termin2	-0.536			
Termin3	-0.530	0.454		
Termin4	-0.508	0.468	0.460	
QualitatN	-0.469	0.110	0.155	0.063

## HMD

Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']

Family: binomial ( logit )

Formula: cbind(Sa\_level\_32, 1 - Sa\_level\_32) ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)

Data: dfHMD

Control: glmerControl(optimizer = "optimx", optCtrl = list(method = "nlminb"))

AIC	BIC	logLik	deviance	df.resid
323.6	347.9	-154.8	309.6	232

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.1020	-0.9198	0.5014	0.8237	1.4949

Random effects:

Groups	Name	Variance	Std.Dev.
--------	------	----------	----------

Szene	(Intercept)	0.38762	0.6226
-------	-------------	---------	--------

Proband	(Intercept)	0.05981	0.2446
---------	-------------	---------	--------

Number of obs: 239, groups: Szene, 24; Proband, 10

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.51926	0.36086	1.439	0.1502
Termin2	0.06504	0.40289	0.161	0.8717
Termin3	-0.41703	0.39664	-1.051	0.2931
Termin4	0.73525	0.41724	1.762	0.0780
QualitatN	-0.48448	0.28520	-1.699	0.0894

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3	Termn4
Termin2	-0.569			
Termin3	-0.620	0.503		
Termin4	-0.534	0.467	0.473	
QualitatN	-0.479	0.058	0.148	0.035




Abbildung A.7: DHARMa Residual Analyse LMM Vorhersage

## A.5.2 Deskriptive Statistik

### Gruppe

Descriptive statistics by group

group: M2D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	240	67.71	46.07	100	72.14	0	0	100	100	-0.75	-1.4	2.97

group: M3D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	228	62.94	47.6	100	66.03	0	0	100	100	-0.53	-1.69	3.15

group: HMD

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	239	59.62	48.2	100	61.92	0	0	100	100	-0.39	-1.81	3.12

### Qualitat

Descriptive statistics by group

group: H

## A Anhang

---

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 353  67 46.25   100  71.2  0  0 100  100 -0.72  -1.45 2.46
```

-----  
group: N

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 354  59.89 48.21   100  62.32  0  0 100  100 -0.4  -1.81 2.56
```

[1] "M2D"

Descriptive statistics by group

group: H

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 120  69.58 45.51   100  74.48  0  0 100  100 -0.84  -1.27 4.15
```

-----  
group: N

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 120  65.83 46.74   100  69.79  0  0 100  100 -0.66  -1.54 4.27
```

[1] "M3D"

Descriptive statistics by group

group: H

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 113  66.81 46.58   100  70.88  0  0 100  100 -0.7  -1.48 4.38
```

-----  
group: N

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 115  59.13 48.48   100  61.29  0  0 100  100 -0.37  -1.84 4.52
```

[1] "HMD"

Descriptive statistics by group

group: H

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 120  64.58 46.92   100  68.23  0  0 100  100 -0.6  -1.6 4.28
```

-----  
group: N

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 119  54.62 49.14   100  55.67  0  0 100  100 -0.18  -1.95 4.5
```

## Termin

Descriptive statistics by group

group: 1

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 188  60.37 48.36   100  62.83  0  0 100  100 -0.42  -1.8 3.53
```

-----  
group: 2

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 172  60.47 48.74   100  63.04  0  0 100  100 -0.42  -1.82 3.72
```

-----  
group: 3

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 177  64.69 46.88   100  68.18  0  0 100  100 -0.61  -1.59 3.52
```

-----  
group: 4

```
vars  n mean  sd median trimmed mad min max range skew kurtosis se
X1    1 170  68.53 45.13   100  73.16  0  0 100  100 -0.79  -1.31 3.46
```

[1] "M2D"

Descriptive statistics by group

```
group: 1
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 62 61.29 48.26   100    64  0  0 100   100 -0.45   -1.79 6.13
-----
group: 2
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 58 62.07 48.95   100   64.58  0  0 100   100 -0.48   -1.8 6.43
-----
group: 3
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 61 75.41 42.45   100   81.63  0  0 100   100 -1.15   -0.63 5.44
-----
group: 4
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 59 72.03 43.82   100   76.53  0  0 100   100 -0.96   -1.02 5.7
```

[1] "M3D"

Descriptive statistics by group

```
group: 1
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 65 65.38 46.71   100   68.87  0  0 100   100 -0.63   -1.57 5.79
-----
group: 2
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 56 61.61 48.61   100   64.13  0  0 100   100 -0.46   -1.8 6.5
-----
group: 3
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 55 69.09 45.63   100   73.33  0  0 100   100 -0.8   -1.33 6.15
-----
group: 4
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 52 54.81 49.76   100   55.95  0  0 100   100 -0.19   -1.98 6.9
```

[1] "HMD"

Descriptive statistics by group

```
group: 1
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 61 54.1 50.25   100   55.1  0  0 100   100 -0.16   -2.01 6.43
-----
group: 2
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 58 57.76 49.38   100   59.38  0  0 100   100 -0.31   -1.92 6.48
-----
group: 3
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 61  50 49.16   50    50 74.13  0 100   100  0   -1.98 6.29
-----
group: 4
  vars n mean   sd median trimmed mad min max range skew kurtosis se
X1    1 59 77.12 39.74   100   82.65  0  0 100   100 -1.25   -0.26 5.17
```

## A.6 Statistik Usability

### A.6.1 Linears Mixed Effect Model

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 18 0.86 0.68 0.87 0.87 0.79 -0.27 1.93 2.2 0.25 -1.26 0.16
```

```
[1] "AIC"
```

```
[1] 188.4863
```

```
[1] "BIC"
```

```
[1] 235.5879
```

```
Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']
Formula: Usab ~ Gruppe * Termin + Gruppe * Qualitat + (1 | Probnr)
Data: dfA
```

```
REML criterion at convergence: 154.5
```

```
Scaled residuals:
```

```
Min      1Q  Median      3Q      Max
-3.8035 -0.4603 -0.0349  0.4635  2.7144
```

```
Random effects:
```

```
Groups   Name          Variance Std.Dev.
Probnr   (Intercept) 0.26641 0.5161
Residual                0.09989 0.3161
```

```
Number of obs: 118, groups: Probnr, 30
```

```
Fixed effects:
```

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.800000	0.191389	41.643118	4.180	0.000146 ***
GruppeHMD	-0.173333	0.273723	43.322970	-0.633	0.529904
GruppeM3D	-0.466785	0.275560	44.340614	-1.694	0.097289 .
Termin2	0.075054	0.174037	76.136441	0.431	0.667505
Termin3	0.194409	0.154938	76.136441	1.255	0.213406
Termin4	0.048172	0.166950	76.136441	0.289	0.773716
QualitatN	-0.002151	0.126930	76.136441	-0.017	0.986527
GruppeHMD:Termin2	0.191613	0.225129	76.136441	0.851	0.397369
GruppeM3D:Termin2	0.166303	0.224441	76.136469	0.741	0.460993
GruppeHMD:Termin3	0.012258	0.209722	76.136441	0.058	0.953544
GruppeM3D:Termin3	0.140252	0.213540	76.408855	0.657	0.513287
GruppeHMD:Termin4	0.325161	0.219696	76.136441	1.480	0.142986
GruppeM3D:Termin4	0.375377	0.222410	76.387558	1.688	0.095534 .
GruppeHMD:QualitatN	-0.097849	0.162838	76.136441	-0.601	0.549692
GruppeM3D:QualitatN	0.015721	0.163726	76.141685	0.096	0.923757

```
---
```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']
Formula: Usab ~ Gruppe + Termin + Qualitat + (1 | Probnr)
Data: dfA
```

```
REML criterion at convergence: 145.2
```

```
Scaled residuals:
```

```
Min      1Q  Median      3Q      Max
```

-4.0305 -0.4034 -0.0243 0.4630 3.0372

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	0.26674	0.5165
	Residual	0.09654	0.3107

Number of obs: 118, groups: Probnr, 30

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.71817	0.17843	32.23300	4.025	0.000323 ***
GruppeHMD	-0.09000	0.24119	26.98667	-0.373	0.711956
GruppeM3D	-0.29257	0.24167	27.18640	-1.211	0.236473
Termin2	0.20175	0.08217	84.13026	2.455	0.016132 *
Termin3	0.25249	0.08194	84.32228	3.081	0.002782 **
Termin4	0.28701	0.08342	84.32102	3.441	0.000905 ***
QualitatN	-0.05029	0.05918	84.13426	-0.850	0.397873

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	GrpHMD	GrpM3D	Termin2	Termin3	Termin4
GruppeHMD		-0.676				
GruppeM3D	-0.676		0.499			
Termin2	-0.198	0.000	0.000			
Termin3	-0.210	0.000	0.008	0.507		
Termin4	-0.197	0.000	0.008	0.519	0.508	
QualitatN	-0.099	0.000	-0.001	-0.216	-0.133	-0.229

## A.6.2 Modelle

### M2D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Usab ~ Qualitat + Termin + (1 | Probnr)

Data: dfAM2D

REML criterion at convergence: 43.7

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.27340	-0.45651	-0.09977	0.60013	1.72127

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	0.26402	0.5138
	Residual	0.07382	0.2717

Number of obs: 40, groups: Probnr, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.800000	0.183804	12.705018	4.352	0.000825 ***
QualitatN	-0.002151	0.109119	26.000000	-0.020	0.984427
Termin2	0.075054	0.149617	26.000000	0.502	0.620143
Termin3	0.194409	0.133197	26.000000	1.460	0.156390
Termin4	0.048172	0.143524	26.000000	0.336	0.739838

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

## Correlation of Fixed Effects:

```
(Intr) QulttN Termn2 Termn3
QualitatN 0.000
Termin2 -0.268 -0.583
Termin3 -0.302 -0.410 0.609
Termin4 -0.280 -0.532 0.654 0.604
```

## M3D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Usab ~ Qualitat + Termin + (1 | Probnr)

Data: dfAM3D

REML criterion at convergence: 38.5

## Scaled residuals:

```
Min      1Q  Median      3Q      Max
-1.6066 -0.5717 -0.1020  0.3668  1.8687
```

## Random effects:

```
Groups  Name          Variance Std.Dev.
Probnr  (Intercept) 0.15016  0.3875
Residual                0.07457  0.2731
```

Number of obs: 38, groups: Probnr, 10

## Fixed effects:

```
Estimate Std. Error      df t value Pr(>|t|)
(Intercept) 0.33317    0.15643 17.47558  2.130  0.04767 *
QualitatN   0.01365    0.08935 24.16227  0.153  0.87981
Termin2     0.24137    0.12245 24.15718  1.971  0.06027 .
Termin3     0.33387    0.12690 24.38134  2.631  0.01453 *
Termin4     0.42276    0.12690 24.38134  3.331  0.00275 **
```

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

## Correlation of Fixed Effects:

```
(Intr) QulttN Termn2 Termn3
QualitatN -0.286
Termin2 -0.410 0.073
Termin3 -0.364 -0.042 0.477
Termin4 -0.364 -0.042 0.477 0.485
```

## HMD

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Usab ~ Qualitat + Termin + (1 | Probnr)

Data: dfAHMD

REML criterion at convergence: 66.1

## Scaled residuals:

```
Min      1Q  Median      3Q      Max
-3.1129 -0.2513  0.0269  0.3593  2.2173
```

## Random effects:

```
Groups  Name          Variance Std.Dev.
Probnr  (Intercept) 0.3847  0.6202
Residual                0.1494  0.3865
```



Number of obs: 40, groups: Probnr, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.6267	0.2364	15.2318	2.651	0.0180 *
QualitatN	-0.1000	0.1247	26.0000	-0.802	0.4300
Termin2	0.2667	0.1746	26.0000	1.527	0.1388
Termin3	0.2067	0.1728	26.0000	1.196	0.2426
Termin4	0.3733	0.1746	26.0000	2.138	0.0421 *

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	QualtN	Termn2	Termn3
QualitatN	-0.211			
Termin2	-0.332	-0.143		
Termin3	-0.366	0.000	0.495	
Termin4	-0.332	-0.143	0.510	0.495

## Termin

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Usab ~ Termin + (1 | Probnr)

Data: dfA

REML criterion at convergence: 141.4

Scaled residuals:

Min	1Q	Median	3Q	Max
-4.1407	-0.4121	-0.0649	0.4471	3.1504

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	0.26226	0.5121
	Residual	0.09622	0.3102

Number of obs: 118, groups: Probnr, 30

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.57556	0.10931	44.47001	5.265	3.9e-06 ***
Termin2	0.18667	0.08009	85.14823	2.331	0.02214 *
Termin3	0.24410	0.08107	85.35263	3.011	0.00342 **
Termin4	0.27168	0.08107	85.35263	3.351	0.00120 **

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	Termn2	Termn3
Termin2	-0.366		
Termin3	-0.362	0.494	
Termin4	-0.362	0.494	0.495

## Deskriptive Statistik

[1] "Gruppe"

Descriptive statistics by group

group: M2D

## A Anhang

---

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 40 0.88 0.56 0.87 0.9 0.59 -0.33 1.8 2.13 -0.19 -0.88 0.09
```

-----  
group: HMD

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 40 0.79 0.71 0.67 0.79 0.69 -1 2 3 0.03 -0.58 0.11
```

-----  
group: M3D

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 38 0.58 0.48 0.77 0.6 0.35 -0.67 1.27 1.93 -0.67 -0.68 0.08
```

[1] "Qualitat"

Descriptive statistics by group

group: H

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 59 0.75 0.58 0.87 0.76 0.59 -0.67 2 2.67 -0.12 -0.49 0.08
```

-----  
group: N

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 59 0.75 0.63 0.8 0.75 0.59 -1 1.93 2.93 -0.01 -0.24 0.08
```

[1] "Termin"

Descriptive statistics by group

group: 1

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 30 0.58 0.64 0.53 0.6 0.59 -1 1.67 2.67 -0.32 -0.25 0.12
```

-----  
group: 2

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 30 0.76 0.58 0.8 0.74 0.54 -0.33 1.87 2.2 0.23 -0.58 0.11
```

-----  
group: 3

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 29 0.82 0.59 0.87 0.81 0.49 -0.27 2 2.27 0.05 -0.67 0.11
```

-----  
group: 4

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 29 0.85 0.61 0.87 0.84 0.59 -0.2 1.93 2.13 0.06 -0.97 0.11
```

[1] "M2D"

Descriptive statistics by group

group: H

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 20 0.86 0.52 0.93 0.89 0.54 -0.33 1.67 2 -0.36 -0.69 0.12
```

-----  
group: N

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 20 0.89 0.61 0.87 0.91 0.64 -0.13 1.8 1.93 -0.09 -1.23 0.14
```

[1] "M3D"

Descriptive statistics by group

group: H

```
vars n mean sd median trimmed mad min max range skew kurtosis se
X1 1 19 0.56 0.56 0.87 0.59 0.3 -0.67 1.27 1.93 -0.72 -0.93 0.13
```

```

group: N
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 19 0.59 0.41  0.67    0.6 0.49 -0.13 1.13  1.27 -0.31  -1.31 0.09

```

```
[1] "HMD"
```

Descriptive statistics by group

```

group: H
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 20 0.82 0.65  0.67    0.78 0.74 -0.2  2  2.2 0.36  -1.21 0.14

```

```

-----
group: N
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 20 0.76 0.79  0.67    0.79 0.69  -1  1.93  2.93 -0.12  -0.65 0.18

```

### A.6.3 Residualanalyse

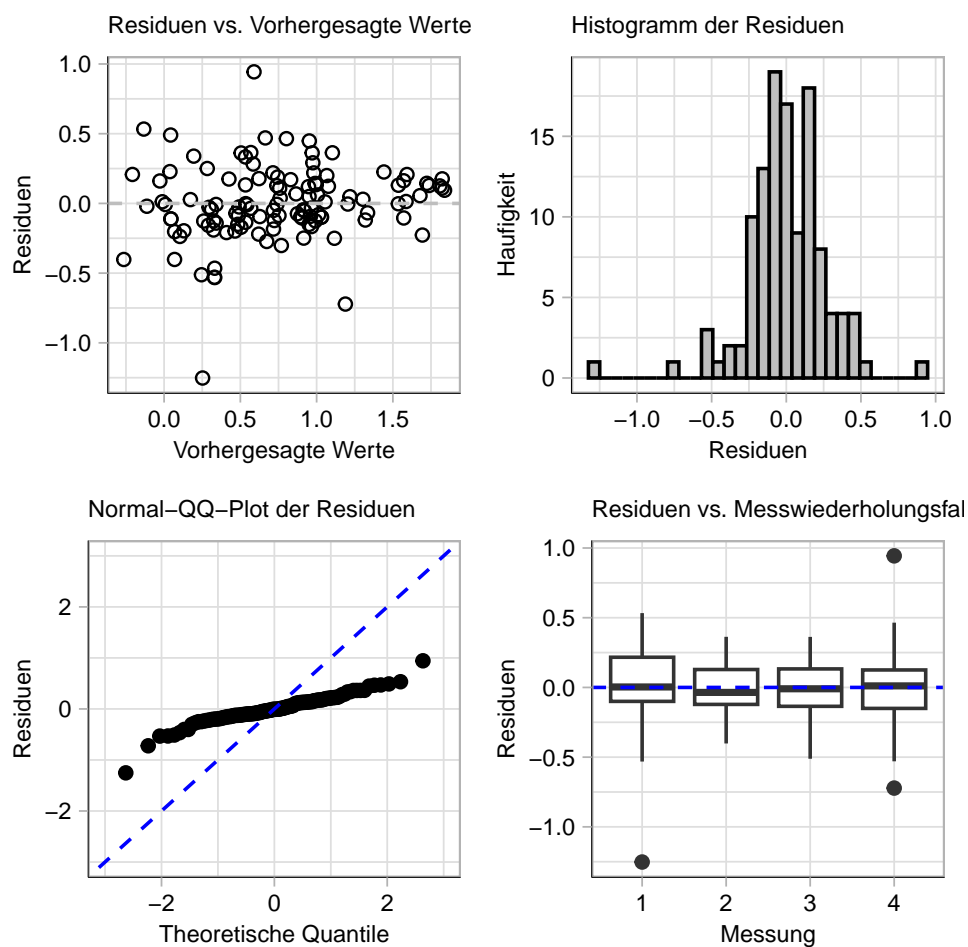


Abbildung A.8: Residuen LMM Usability




Abbildung A.9: DHARMA Residual Analyse LMM Usability

## A.7 Statistik Workload

### A.7.1 Lineares Mixed Effect Model

[1] "AIC"

[1] 675.7661

[1] "BIC"

[1] 722.8678

Linear mixed model fit by REML. t-tests use Satterthwaite's method [`'lmerModLmerTest'`]  
Formula: TLX ~ Gruppe \* Qualitat + Termin \* Gruppe + (1 | Probnr)  
Data: dfa

REML criterion at convergence: 641.8

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.1940	-0.5075	0.0710	0.4126	2.8643

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	37.76	6.145
	Residual	10.55	3.248

Number of obs: 118, groups: Probnr, 30

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	72.14286	2.19802	38.07461	32.822	< 2e-16 ***
GruppeHMD	0.51587	3.13662	39.34767	0.164	0.87020
GruppeM3D	2.70987	3.15355	40.12091	0.859	0.39528
QualitatN	2.36175	1.30436	76.11846	1.811	0.07414 .
Termin2	-3.31797	1.78845	76.11846	-1.855	0.06744 .
Termin3	-4.63326	1.59218	76.11846	-2.910	0.00474 **
Termin4	-3.55799	1.71562	76.11846	-2.074	0.04147 *
GruppeHMD:QualitatN	-2.16334	1.67337	76.11846	-1.293	0.19999
GruppeM3D:QualitatN	-2.78149	1.68250	76.12261	-1.653	0.10241

```

GruppeHMD:Termin2    2.20686    2.31349 76.11846    0.954    0.34315
GruppeM3D:Termin2   -0.05734    2.30642 76.11849   -0.025    0.98023
GruppeHMD:Termin3    3.20469    2.15516 76.11846    1.487    0.14115
GruppeM3D:Termin3    0.21904    2.19488 76.33384    0.100    0.92077
GruppeHMD:Termin4    0.66116    2.25766 76.11846    0.293    0.77043
GruppeM3D:Termin4   -3.89856    2.28600 76.31701   -1.705    0.09219 .

```

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: TLX ~ Gruppe + Termin + Qualitat + (1 | Probnr)

Data: dfA

REML criterion at convergence: 677.1

Scaled residuals:

```

      Min      1Q   Median      3Q      Max
-2.24286 -0.48325  0.03919  0.47459  2.41235

```

Random effects:

```

Groups   Name             Variance Std.Dev.
Probnr   (Intercept)  37.62    6.134
Residual                   11.11    3.334

```

Number of obs: 118, groups: Probnr, 30

Fixed effects:

```

              Estimate Std. Error    df t value Pr(>|t|)
(Intercept)  72.5112      2.0873  31.3274  34.739 < 2e-16 ***
GruppeHMD     0.9524      2.8426  26.9959   0.335 0.740183
GruppeM3D     0.4610      2.8473  27.1656   0.162 0.872575
Termin2      -2.1367      0.8816  84.1164  -2.424 0.017510 *
Termin3      -3.2063      0.8792  84.2795  -3.647 0.000459 ***
Termin4      -4.1978      0.8951  84.2784  -4.690 1.04e-05 ***
QualitatN     0.6408      0.6350  84.1198   1.009 0.315781

```

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

```

      (Intr) GrpHMD GrpM3D Termn2 Termn3 Termn4
GruppeHMD -0.681
GruppeM3D -0.681  0.499
Termin2   -0.182  0.000  0.000
Termin3   -0.193  0.000  0.007  0.507
Termin4   -0.181  0.000  0.007  0.519  0.508
QualitatN -0.091  0.000 -0.001 -0.216 -0.133 -0.229

```

## M2D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: TLX ~ Qualitat + Termin + (1 | Probnr)

Data: dfAM2D

REML criterion at convergence: 217.9

Scaled residuals:

```

      Min      1Q   Median      3Q      Max
-2.22579 -0.53056  0.06393  0.50317  1.63628

```

## A Anhang

---

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	45.33	6.733
	Residual	10.16	3.188

Number of obs: 40, groups: Probnr, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	72.143	2.356	11.989	30.624	9.39e-13 ***
QualitatN	2.362	1.280	26.000	1.845	0.07653 .
Termin2	-3.318	1.756	26.000	-1.890	0.06996 .
Termin3	-4.633	1.563	26.000	-2.964	0.00641 **
Termin4	-3.558	1.684	26.000	-2.113	0.04439 *

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	QulttN	Termn2	Termn3
QualitatN	0.000			
Termin2	-0.246	-0.583		
Termin3	-0.276	-0.410	0.609	
Termin4	-0.256	-0.532	0.654	0.604

## M3D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: TLX ~ Qualitat + Termin + (1 | Probnr)

Data: dfAM3D

REML criterion at convergence: 196.2

Scaled residuals:

Min	1Q	Median	3Q	Max
-1.54583	-0.64168	0.02636	0.48612	1.71184

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	18.801	4.336
	Residual	8.743	2.957

Number of obs: 38, groups: Probnr, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	74.8529	1.7287	17.0389	43.299	< 2e-16 ***
QualitatN	-0.4200	0.9675	24.1831	-0.434	0.6681
Termin2	-3.3753	1.3259	24.1782	-2.546	0.0177 *
Termin3	-4.4117	1.3743	24.3915	-3.210	0.0037 **
Termin4	-7.4541	1.3743	24.3915	-5.424	1.35e-05 ***

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	QulttN	Termn2	Termn3
QualitatN	-0.280			
Termin2	-0.402	0.073		
Termin3	-0.356	-0.042	0.477	
Termin4	-0.356	-0.042	0.477	0.486

## HMD

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: TLX ~ Qualitat + Termin + (1 | Probnr)

Data: dfAHMD

REML criterion at convergence: 224.7

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.0026	-0.3953	0.1194	0.3720	2.6271

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	49.14	7.010
	Residual	12.59	3.549

Number of obs: 40, groups: Probnr, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	72.6587	2.5265	13.1895	28.759	2.74e-13 ***
QualitatN	0.1984	1.1453	26.0000	0.173	0.8638
Termin2	-1.1111	1.6034	26.0000	-0.693	0.4945
Termin3	-1.4286	1.5869	26.0000	-0.900	0.3763
Termin4	-2.8968	1.6034	26.0000	-1.807	0.0824 .

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	QualttN	Termin2	Termin3
QualitatN	-0.181			
Termin2	-0.285	-0.143		
Termin3	-0.314	0.000	0.495	
Termin4	-0.285	-0.143	0.510	0.495

## Termin

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: TLX ~ Termin + (1 | Probnr)

Data: dfA

REML criterion at convergence: 686.7

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.31167	-0.49578	0.06185	0.44194	2.55214

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	35.00	5.916
	Residual	11.12	3.334

Number of obs: 118, groups: Probnr, 30

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	73.1746	1.2398	42.4849	59.021	< 2e-16 ***
Termin2	-1.9444	0.8608	85.1316	-2.259	0.026451 *
Termin3	-3.0883	0.8714	85.3141	-3.544	0.000642 ***
Termin4	-3.9914	0.8714	85.3141	-4.581	1.57e-05 ***

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Correlation of Fixed Effects:
      (Intr) Termn2 Termn3
Termin2 -0.347
Termin3 -0.343  0.494
Termin4 -0.343  0.494  0.495
```

## Residualanalyse




Abbildung A.10: DHARMa Residual Analyse LMM Workload

### A.7.2 Deskriptive Statistik

```
[1] "Insgesamt"
```

```
Descriptive statistics by group
group: H
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 59 70.94 6.65 71.43 70.82 7.06 58.33 85.71 27.38 0.19 -0.75 0.87
-----
group: N
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 59 70.92 7.22 71.43 70.97 7.06 58.33 84.52 26.19 -0.1 -1 0.94
```

```
[1] "Termin"
```

```
Descriptive statistics by group
group: 1
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 30 73.17 6.56 72.62 73.16 7.94 59.52 85.71 26.19 0.01 -0.85 1.2
-----
group: 2
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 30 71.23 6.22 71.43 71.48 5.29 58.33 83.33 25 -0.19 -0.44 1.14
-----
group: 3
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 29 70.07 7.12 69.05 70 7.06 58.33 83.33 25 0.14 -1.1 1.32
```



```
-----
group: 4
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 29 69.17 7.38 66.67 68.95 8.82 58.33 84.52 26.19 0.27  -1.19 1.37
```

```
[1] "M2D"
```

```
Descriptive statistics by group
```

```
group: H
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 20 70.12 6.91 66.67 69.35 3.53 59.52 85.71 26.19 0.79  -0.44 1.54
```

```
-----
group: N
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 20 70.77 7.85 70.24 70.68 6.18 58.33 84.52 26.19 0.17  -0.97 1.76
```

```
Descriptive statistics by group
```

```
group: 1
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 10 72.14 6.76 70.83 71.43 6.18 64.29 85.71 21.43 0.62  -0.95 2.14
```

```
-----
group: 2
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 10 70.71 7.45 69.05 70.68 4.41 58.33 83.33 25 0.34  -0.83 2.36
```

```
-----
group: 3
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 10 68.69 7.92 67.26 68.01 5.29 59.52 83.33 23.81 0.71  -0.95 2.5
```

```
-----
group: 4
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 10 70.24 7.8 68.45 69.94 9.71 58.33 84.52 26.19 0.22  -1.1 2.47
```

```
[1] "M3D"
```

```
Descriptive statistics by group
```

```
group: H
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 19 71.3 6.22 71.43 71.08 5.29 61.9 84.52 22.62 0.54  -0.67 1.43
```

```
-----
group: N
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 19 70.61 5.41 69.05 70.52 7.06 63.1 79.76 16.67 0.09  -1.34 1.24
```

```
Descriptive statistics by group
```

```
group: 1
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 10 74.64 6.25 75 74.4 8.83 66.67 84.52 17.86 0.15  -1.57 1.98
```

```
-----
group: 2
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 10 71.31 4.29 70.24 71.43 3.53 64.29 77.38 13.1 0.1  -1.36 1.36
```

```
-----
group: 3
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 9 70.24 4.76 69.05 70.24 5.29 63.1 79.76 16.67 0.43  -0.53 1.59
```

```
-----
group: 4
  vars n mean  sd median trimmed mad  min  max range skew kurtosis  se
X1    1 9 67.2 5.71 65.48 67.2 3.53 61.9 78.57 16.67 0.8  -0.96 1.9
```

[1] "HMD"

```
Descriptive statistics by group
group: H
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 20 71.43 7.03 73.21 71.95 6.18 58.33 79.76 21.43 -0.62 -1.1 1.57
-----
group: N
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 20 71.37 8.32 72.62 71.65 9.71 58.33 82.14 23.81 -0.41 -1.47 1.86

Descriptive statistics by group
group: 1
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 10 72.74 7.09 72.62 73.21 7.94 59.52 82.14 22.62 -0.53 -1.03 2.24
-----
group: 2
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 10 71.67 7.09 73.21 72.32 6.18 59.52 78.57 19.05 -0.76 -1.06 2.24
-----
group: 3
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 10 71.31 8.43 73.21 71.88 9.71 58.33 79.76 21.43 -0.44 -1.62 2.66
-----
group: 4
  vars n mean sd median trimmed mad min max range skew kurtosis se
X1    1 10 69.88 8.6 72.62 69.94 11.47 58.33 80.95 22.62 -0.13 -1.85 2.72
```

## A.8 Statistik Immersion

### A.8.1 Linear Mixed Effect Model

[1] "AIC"

[1] 314.0382

[1] "BIC"

[1] 361.1398

```
Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']
Formula: Immersion ~ Gruppe * Qualitat + Gruppe * Termin + (1 | Probnr)
Data: dfA
```

REML criterion at convergence: 280

Scaled residuals:

	Min	1Q	Median	3Q	Max
	-2.99148	-0.51937	0.01338	0.54452	2.25697

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	0.7252	0.8516
Residual		0.3615	0.6012

Number of obs: 118, groups: Probnr, 30

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.22000	0.32964	46.01530	0.667	0.508
GruppeHMD	0.19500	0.47260	48.17479	0.413	0.682
GruppeM3D	0.14002	0.47644	49.47644	0.294	0.770
QualitatN	-0.39032	0.24145	76.14220	-1.617	0.110
Termin2	0.35226	0.33106	76.14220	1.064	0.291
Termin3	0.15516	0.29473	76.14220	0.526	0.600
Termin4	0.37323	0.31758	76.14220	1.175	0.244
GruppeHMD:QualitatN	0.30282	0.30976	76.14220	0.978	0.331
GruppeM3D:QualitatN	0.31028	0.31144	76.14868	0.996	0.322
GruppeHMD:Termin2	-0.33476	0.42825	76.14220	-0.782	0.437
GruppeM3D:Termin2	-0.32026	0.42694	76.14223	-0.750	0.455
GruppeHMD:Termin3	0.10484	0.39894	76.14220	0.263	0.793
GruppeM3D:Termin3	-0.05167	0.40610	76.47904	-0.127	0.899
GruppeHMD:Termin4	-0.05573	0.41791	76.14220	-0.133	0.894
GruppeM3D:Termin4	-0.69195	0.42298	76.45269	-1.636	0.106

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']  
 Formula: Immersion ~ Gruppe + Qualitat + Termin + (1 | Probnr)  
 Data: dfA

REML criterion at convergence: 282

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.10886	-0.55349	-0.06424	0.46392	2.31657

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	0.7302	0.8545
	Residual	0.3528	0.5940

Number of obs: 118, groups: Probnr, 30

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.24531	0.30313	33.78123	0.809	0.424
GruppeHMD	0.27500	0.40456	26.92986	0.680	0.502
GruppeM3D	0.03828	0.40559	27.17815	0.094	0.926
QualitatN	-0.14356	0.11314	84.11754	-1.269	0.208
Termin2	0.06974	0.15708	84.11256	0.444	0.658
Termin3	0.13266	0.15661	84.35197	0.847	0.399
Termin4	0.08349	0.15944	84.35040	0.524	0.602

Correlation of Fixed Effects:

	(Intr)	GrpHMD	GrpM3D	QualttN	Termn2	Termn3
GruppeHMD	-0.667					
GruppeM3D	-0.668	0.499				
QualitatN	-0.111	0.000	-0.001			
Termin2	-0.223	0.000	0.000	-0.216		
Termin3	-0.237	0.000	0.009	-0.133	0.507	
Termin4	-0.222	0.000	0.009	-0.229	0.519	0.508

## A.8.2 Modelle Gruppen

### M2D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']  
 Formula: Immersion ~ Qualitat + Termin + (1 | Probnr)  
 Data: dfAM2D

## A Anhang

---

REML criterion at convergence: 83.5

Scaled residuals:

Min	1Q	Median	3Q	Max
-1.68607	-0.57726	-0.03059	0.39655	2.38345

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	1.221	1.1051
	Residual	0.203	0.4506

Number of obs: 40, groups: Probnr, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.2200	0.3774	11.2281	0.583	0.5714
QualitatN	-0.3903	0.1810	26.0000	-2.157	0.0404 *
Termin2	0.3523	0.2481	26.0000	1.420	0.1676
Termin3	0.1552	0.2209	26.0000	0.702	0.4886
Termin4	0.3732	0.2380	26.0000	1.568	0.1289

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	QulttN	Termn2	Termn3
QualitatN	0.000			
Termin2	-0.217	-0.583		
Termin3	-0.244	-0.410	0.609	
Termin4	-0.226	-0.532	0.654	0.604

## M3D

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Immersion ~ Qualitat + Termin + (1 | Probnr)

Data: dfAM3D

REML criterion at convergence: 81.8

Scaled residuals:

Min	1Q	Median	3Q	Max
-1.9576	-0.6240	0.1014	0.6978	1.2942

Random effects:

Groups	Name	Variance	Std.Dev.
Probnr	(Intercept)	0.5988	0.7738
	Residual	0.2711	0.5207

Number of obs: 38, groups: Probnr, 10

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.36006	0.30700	16.78369	1.173	0.257
QualitatN	-0.08012	0.17038	24.12631	-0.470	0.642
Termin2	0.03199	0.23348	24.12155	0.137	0.892
Termin3	0.10427	0.24201	24.33152	0.431	0.670
Termin4	-0.31795	0.24201	24.33152	-1.314	0.201

Correlation of Fixed Effects:

	(Intr)	QulttN	Termn2	Termn3
QualitatN	-0.277			

|XXX

```

Termin2  -0.398  0.073
Termin3  -0.353 -0.042  0.477
Termin4  -0.353 -0.042  0.477  0.486

```

## HMD

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Immersion ~ Qualitat + Termin + (1 | Probnr)

Data: dfAHMD

REML criterion at convergence: 104

Scaled residuals:

```

      Min      1Q  Median      3Q      Max
-2.4040 -0.3626  0.1011  0.4634  1.7778

```

Random effects:

```

Groups   Name          Variance Std.Dev.
Probnr   (Intercept)  0.3553  0.5961
Residual                0.6036  0.7769

```

Number of obs: 40, groups: Probnr, 10

Fixed effects:

```

              Estimate Std. Error    df t value Pr(>|t|)
(Intercept)   0.4150    0.3255 27.8924   1.275   0.213
QualitatN    -0.0875    0.2508 26.0000  -0.349   0.730
Termin2       0.0175    0.3511 26.0000   0.050   0.961
Termin3       0.2600    0.3475 26.0000   0.748   0.461
Termin4       0.3175    0.3511 26.0000   0.904   0.374

```

Correlation of Fixed Effects:

```

              (Intr) QulttN Termn2 Termn3
QualitatN -0.308
Termin2    -0.484 -0.143
Termin3    -0.534  0.000  0.495
Termin4    -0.484 -0.143  0.510  0.495

```

## Termin

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Immersion ~ Qualitat + Termin + (1 | Probnr)

Data: dfAM3D

REML criterion at convergence: 81.8

Scaled residuals:

```

      Min      1Q  Median      3Q      Max
-1.9576 -0.6240  0.1014  0.6978  1.2942

```

Random effects:

```

Groups   Name          Variance Std.Dev.
Probnr   (Intercept)  0.5988  0.7738
Residual                0.2711  0.5207

```

Number of obs: 38, groups: Probnr, 10

Fixed effects:

```

              Estimate Std. Error    df t value Pr(>|t|)
(Intercept)   0.36006    0.30700 16.78369   1.173   0.257

```

QualitatN	-0.08012	0.17038	24.12631	-0.470	0.642
Termin2	0.03199	0.23348	24.12155	0.137	0.892
Termin3	0.10427	0.24201	24.33152	0.431	0.670
Termin4	-0.31795	0.24201	24.33152	-1.314	0.201

Correlation of Fixed Effects:

(Intr)	QulttN	Termn2	Termn3
QualitatN	-0.277		
Termin2	-0.398	0.073	
Termin3	-0.353	-0.042	0.477
Termin4	-0.353	-0.042	0.477

### A.8.3 Residualanalyse

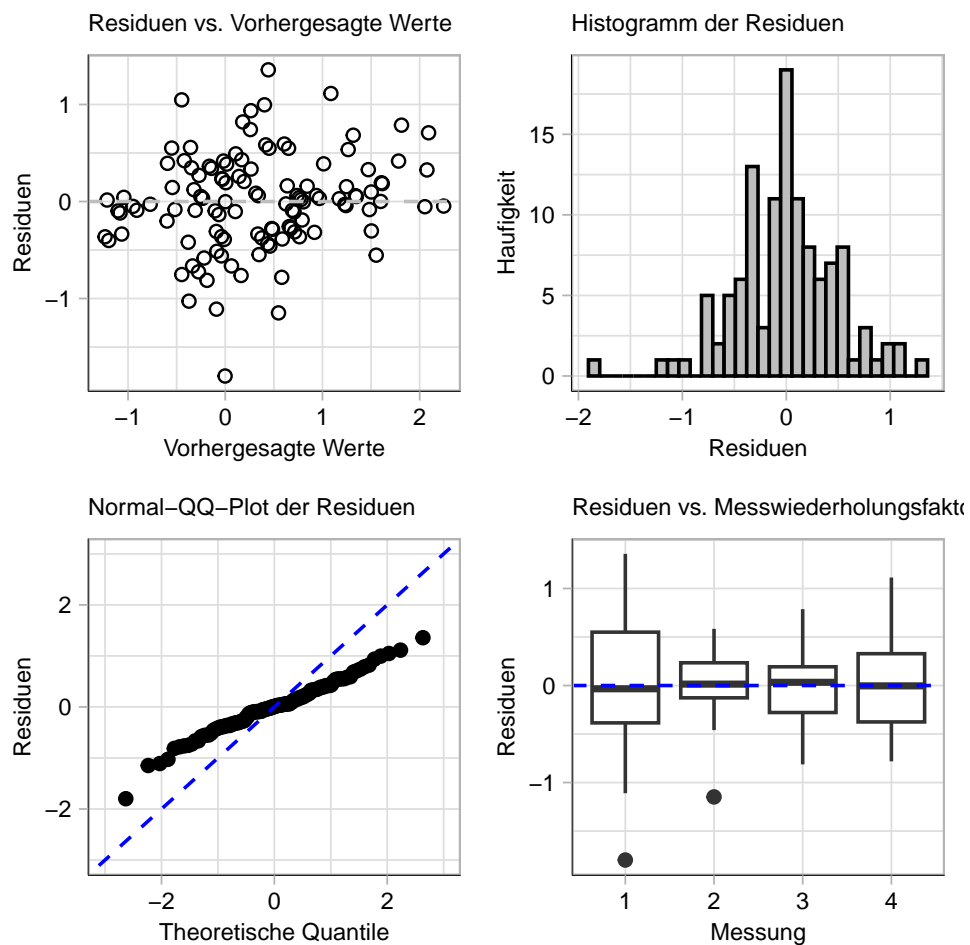



Abbildung A.11: Residuen LMM Immersion



## A.9 Statistik Sicherheitsempfinden

### A.9.1 Kummulatives Link Mixed Effect Model

Cumulative Link Mixed Model fitted with the Laplace approximation

formula: Ratef ~ Gruppe + Termin + Qualitat + Verkehrsaufkommen + (1 | Proband) + (1 | Szene)

data: df

```
link threshold nobs logLik AIC niter max.grad cond.H
logit flexible 707 -1244.05 2526.10 2158(18101) 1.84e-03 1.3e+03
```

Random effects:

```
Groups Name Variance Std.Dev.
Proband (Intercept) 3.1313 1.7695
Szene (Intercept) 0.3088 0.5557
```

Number of groups: Proband 30, Szene 24

Coefficients:

```
Estimate Std. Error z value Pr(>|z|)
GruppeM3D -1.5769 0.8126 -1.940 0.05233 .
GruppeHMD -0.2075 0.8085 -0.257 0.79749
Termin2 0.3370 0.2022 1.667 0.09555 .
Termin3 0.8634 0.2011 4.293 1.77e-05 ***
Termin4 0.3714 0.1998 1.858 0.06312 .
QualitatN -0.1512 0.1382 -1.094 0.27383
VerkehrsaufkommenM -1.0505 0.3009 -3.492 0.00048 ***
VerkehrsaufkommenH -1.3027 0.3576 -3.642 0.00027 ***
```

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Threshold coefficients:

```
Estimate Std. Error z value
1|2 -6.3647 0.7328 -8.685
2|3 -5.5656 0.6833 -8.145
3|4 -4.5947 0.6525 -7.042
4|5 -3.6494 0.6389 -5.712
5|6 -2.4816 0.6297 -3.941
6|7 -1.4550 0.6254 -2.326
```

```
7|8 -0.0981 0.6232 -0.157
8|9 1.3800 0.6254 2.207
9|10 3.0530 0.6407 4.765
```

## M2D

Cumulative Link Mixed Model fitted with the Laplace approximation

```
formula: Ratef ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
data:    dfM2D
```

```
link threshold nobs logLik AIC niter max.grad cond.H
logit flexible 240 -404.82 837.64 1163(4656) 3.54e-04 2.7e+02
```

Random effects:

```
Groups Name Variance Std.Dev.
Szene (Intercept) 0.4004 0.6328
Proband (Intercept) 1.9083 1.3814
Number of groups: Szene 24, Proband 10
```

Coefficients:

```
Estimate Std. Error z value Pr(>|z|)
Termin2 0.46569 0.34623 1.345 0.1786
Termin3 1.22208 0.34521 3.540 0.0004 ***
Termin4 0.52266 0.34143 1.531 0.1258
QualitatN 0.01542 0.23664 0.065 0.9480
```

---

```
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Threshold coefficients:

```
Estimate Std. Error z value
1|3 -6.1531 1.1440 -5.379
3|4 -5.0401 0.8022 -6.283
4|5 -3.0188 0.5971 -5.056
5|6 -1.7754 0.5586 -3.178
6|7 -0.4785 0.5442 -0.879
7|8 0.7941 0.5447 1.458
8|9 2.4381 0.5628 4.332
9|10 4.2408 0.6278 6.755
```

## M3D

Cumulative Link Mixed Model fitted with the Laplace approximation

```
formula: Ratef ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
data:    dfM3D
```

```
link threshold nobs logLik AIC niter max.grad cond.H
logit flexible 228 -402.93 835.87 1367(8146) 2.34e-04 8.2e+02
```

Random effects:

```
Groups Name Variance Std.Dev.
Szene (Intercept) 0.8497 0.9218
Proband (Intercept) 6.2076 2.4915
Number of groups: Szene 24, Proband 10
```

Coefficients:

```
Estimate Std. Error z value Pr(>|z|)
```



```

Termin2      1.0212      0.3847      2.654  0.00794 **
Termin3      0.8874      0.3824      2.320  0.02032 *
Termin4      0.7047      0.3771      1.869  0.06165 .
QualitatN   -0.1853      0.2585     -0.717  0.47347
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Threshold coefficients:

	Estimate	Std. Error	z value
1 2	-3.6234	0.9637	-3.760
2 3	-2.6335	0.9100	-2.894
3 4	-1.8153	0.8901	-2.039
4 5	-0.8235	0.8792	-0.937
5 6	0.1043	0.8755	0.119
6 7	0.9049	0.8758	1.033
7 8	2.2468	0.8837	2.542
8 9	4.0455	0.9113	4.440
9 10	5.2672	0.9552	5.514

## HMD

Cumulative Link Mixed Model fitted with the Laplace approximation

```

formula: Ratef ~ Termin + Qualitat + (1 | Proband) + (1 | Szene)
data:    dfHMD

```

```

link threshold nobs logLik AIC niter max.grad cond.H
logit flexible 239 -435.96 901.93 1384(4229) 2.67e-04 3.2e+02

```

Random effects:

Groups	Name	Variance	Std.Dev.
Szene	(Intercept)	0.557	0.7464
Proband	(Intercept)	1.491	1.2211

Number of groups: Szene 24, Proband 10

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
Termin2	-0.3312	0.3396	-0.975	0.329
Termin3	0.3000	0.3361	0.893	0.372
Termin4	-0.2015	0.3424	-0.589	0.556
QualitatN	-0.2161	0.2327	-0.929	0.353

Threshold coefficients:

	Estimate	Std. Error	z value
1 2	-6.5479	1.1293	-5.798
2 3	-5.4357	0.7803	-6.966
3 4	-3.8635	0.5866	-6.587
4 5	-3.3550	0.5606	-5.984
5 6	-1.9543	0.5238	-3.731
6 7	-0.9590	0.5138	-1.866
7 8	0.4867	0.5096	0.955
8 9	1.4841	0.5187	2.861
9 10	3.1984	0.5651	5.660

## A.9.2 Deskriptive Statistik

## Gruppe

Descriptive statistics by group

group: M2D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	240	7.13	1.64	7	7.21	1.48	1	10	9	-0.45	0.03	0.11

group: M3D

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	228	5.9	2.53	7	6.07	1.48	1	10	9	-0.62	-0.59	0.17

group: HMD

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	239	6.93	1.87	7	7.01	1.48	1	10	9	-0.38	-0.2	0.12

## Qualitat

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	353	6.78	2.05	7	6.95	1.48	1	10	9	-0.77	0.46	0.11

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	354	6.55	2.15	7	6.75	1.48	1	10	9	-0.79	0.36	0.11

[1] "M2D"

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	120	7.19	1.67	7	7.28	1.48	3	10	7	-0.41	-0.51	0.15

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	120	7.08	1.62	7	7.14	1.48	1	10	9	-0.5	0.56	0.15

[1] "M3D"

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	113	6.06	2.41	7	6.26	1.48	1	10	9	-0.71	-0.35	0.23

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	115	5.74	2.64	6	5.86	2.97	1	10	9	-0.51	-0.83	0.25

[1] "HMD"

Descriptive statistics by group

group: H

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	120	7.06	1.87	7	7.11	1.48	1	10	9	-0.4	-0.11	0.17

group: N

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
X1	1	119	6.8	1.87	7	6.91	1.48	2	10	8	-0.36	-0.33	0.17

## Termin

```

Descriptive statistics by group
group: 1
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1 188 6.29 2.33      7   6.45 1.48  1 10   9 -0.55   -0.33 0.17
-----
group: 2
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1 172 6.68 1.98      7   6.85 1.48  1 10   9 -0.84    0.82 0.15
-----
group: 3
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1 177 7.03 2.04      7   7.22 1.48  1 10   9 -0.94    0.98 0.15
-----
group: 4
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1 170 6.68 1.98      7   6.86 1.48  1 10   9 -0.82    0.62 0.15

[1] "M2D"

```

```

Descriptive statistics by group
group: 1
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  62 6.77 1.77      7   6.82 1.48  3 10   7 -0.27   -0.72 0.22
-----
group: 2
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  58 7.09 1.6      7   7.15 1.48  1 10   9 -0.79    1.98 0.21
-----
group: 3
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  61 7.59 1.54      8   7.67 1.48  4 10   6 -0.46   -0.31 0.2
-----
group: 4
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  59 7.08 1.57      7   7.12 1.48  4 10   6 -0.19   -0.96 0.2

[1] "M3D"

```

```

Descriptive statistics by group
group: 1
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  65 5.29 2.71      6   5.3 2.97  1 10   9 -0.18   -1.17 0.34
-----
group: 2
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  56 6.21 2.44      7   6.41 1.48  1 10   9 -0.69   -0.34 0.33
-----
group: 3
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  55 6.27 2.48      7   6.49 1.48  1 10   9 -0.88   -0.05 0.33
-----
group: 4
  vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1     1  52 5.92 2.36      7   6.17 1.48  1  9   8 -0.83   -0.32 0.33

[1] "HMD"

```

```

Descriptive statistics by group
group: 1

```

```

vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1    1 61 6.87 2.05      7    6.96 2.97  1 10   9 -0.41   -0.27 0.26
-----
group: 2
vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1    1 58 6.72 1.74      7    6.81 1.48  2 10   8 -0.37   -0.08 0.23
-----
group: 3
vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1    1 61 7.16 1.87      7    7.24 1.48  3 10   7 -0.35   -0.43 0.24
-----
group: 4
vars  n mean  sd median trimmed  mad min max range  skew kurtosis  se
X1    1 59 6.95 1.82      7    7.04 1.48  2 10   8 -0.38   -0.41 0.24

```

## A.10 Statistik LiDAR Abstand

### A.10.1 Lineares Mixed Effect Model

Linear mixed model fit by REML. t-tests use Satterthwaite's method ['lmerModLmerTest']

Formula: Absfehler ~ Gruppe + (1 | Proband)

Data: dff

REML criterion at convergence: 46.9

Scaled residuals:

Min	1Q	Median	3Q	Max
-1.4795	-0.6799	-0.2616	0.4343	2.9807

Random effects:

Groups	Name	Variance	Std.Dev.
Proband	(Intercept)	0.007344	0.0857
	Residual	0.084953	0.2915

Number of obs: 84, groups: Proband, 14

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.36042	0.06677	30.66008	5.398	7.09e-06 ***
GruppeL-HMD	-0.10486	0.10199	30.66008	-1.028	0.3119
GruppeR-HMD	-0.13542	0.08414	68.00000	-1.609	0.1122
GruppeC-HMD	-0.17986	0.10199	30.66008	-1.764	0.0878 .

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

	(Intr)	GL-HMD	GR-HMD
GruppeL-HMD			
GruppeR-HMD	-0.655		
GruppeC-HMD	-0.630	0.413	
	-0.655	0.546	0.413




Abbildung A.13: DHARMA Residual Analyse

## A.10.2 Deskriptive Statistik

Descriptive statistics by group

group: R-M

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	24	0.36	0.39	0.3	0.31	0.44	0	1.3	1.3	0.86	-0.34	0.08

group: L-HMD

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	18	0.26	0.28	0.2	0.23	0.3	0	0.9	0.9	0.81	-0.39	0.07

group: R-HMD

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	24	0.22	0.26	0.12	0.18	0.19	0	0.9	0.9	1.06	0.18	0.05

group: C-HMD

vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se	
X1	1	18	0.18	0.23	0.1	0.15	0.15	0	0.9	0.9	1.57	2.27	0.06