

---

# **Silent Testing der Fahrzeugsteuerung zur Identifikation von Herausforderungen und Möglichkeiten des Automatisierten Fahrens von Straßenbahnen**

Vom Fachbereich Maschinenbau an der  
Technischen Universität Darmstadt  
zur Erlangung des Grades eines  
Doktor-Ingenieurs (Dr.-Ing.)  
genehmigte

## **Dissertation**

vorgelegt von

**Timm Ruppert M. Sc.**

aus Bad Schwalbach

Berichterstatter: Prof. Dr.-Ing. Steven Peters  
Mitberichterstatter: Prof. Dr.-Ing. Andreas Oetting

Tag der Einreichung: 12.01.2024  
Tag der mündlichen Prüfung: 16.04.2024

Darmstadt 2024

D 17

---

Timm Ruppert M. Sc.: Silent Testing der Fahrzeugsteuerung zur Identifikation von Herausforderungen und Möglichkeiten des Automatisierten Fahrens von Straßenbahnen

Darmstadt, Technische Universität Darmstadt

Jahr der Veröffentlichung der Dissertation auf TUPrints: 2024

URN: urn:nbn:de:tuda-tuprints-263627

URI: <https://tuprints.ulb.tu-darmstadt.de/id/eprint/26362>

Tag der mündlichen Prüfung: 16.04.2024

Veröffentlicht unter CC BY-SA 4.0 International

<https://creativecommons.org/licenses>

# Vorwort

Die vorliegende Arbeit wurde während meiner Tätigkeit als wissenschaftlicher Mitarbeiter (WiMi) am Fachgebiet Fahrzeugtechnik (FZD) der Technischen Universität Darmstadt angefertigt und von vielen Menschen begleitet, denen ich an dieser Stelle meinen Dank aussprechen möchte.

Mein ganz besonderer Dank gilt Prof. Dr.-Ing. Steven Peters, der als Doktorvater diese Arbeit betreut hat. Ohne seine großzügige Unterstützung und sein Vertrauen, aber auch den durch seine Berufung begründeten frischen Wind und einer von mir benötigten Portion Realismus wäre diese Arbeit vermutlich immer noch nicht fertig. Den wissenschaftlichen Diskurs zu den Abenteuern der Straßenbahnautomatisierung habe ich stets sehr genossen. Ein ebenso herzlicher Dank geht an Prof. Dr. rer. nat. Hermann Winner, der mich vor seiner Pension und der Berufung von Professor Peters begleitet hat. Sein Weg die wissenschaftlichen Rätsel dieser Welt zu betrachten und zu hinterfragen hat mich sehr geprägt und wird mich auch weiterhin begleiten. Bei Prof. Dr.-Ing. Andreas Oetting vom Institut für Bahnsysteme und Bahntechnik möchte ich mich für das Interesse zu dieser Forschungsarbeit sowie der Übernahme der Rolle des Zweitgutachters bedanken.

In meiner Zeit als WiMi hatte ich das Glück viele motivierte Studierende kennenzulernen. Ein großer Dank gilt daher den zahlreichen studentischen Hilfskräften (insbesondere Christian Guba) sowie Abschlussarbeiten, die mit großem Engagement und Einsatz meine Forschungsarbeit unterstützt haben. Meinen hochgeschätzten Kollegen möchte ich ebenso meine Dankbarkeit ausdrücken. Ihre vermutlich einzigartige kollegiale Art, die stete Unterstützung und fachlichen Diskussionen haben meinen Arbeitsalltag sowie die Forschung bereichert und mir geholfen, über den Tellerrand hinauszublicken. Insbesondere Patrick Pintscher, der mit mir das MAAS Projekt bearbeitet hat, sowie Lukas Elster, der mit mir Sensorfehler gejagt hat, möchte ich für die gemeinsame Zeit danken. Der HEAG mobilo GmbH sowie ihren Mitarbeitern danke ich für die Zusammenarbeit und die Ermöglichung des praktischen Teils dieser Forschung.

Meine Familie und Freunde haben mich in den letzten Jahren stets unterstützt und mir vor allem mit Verständnis zu meiner Abkömmlichkeit den Rücken freigehalten. Dafür bin ich ihnen äußerst dankbar. Insbesondere meinen Eltern danke ich von Herzen für die lange Unterstützung meiner beruflichen Entwicklung.

Der größte Dank gilt meiner Frau Emina, die faktisch alle privaten Pflichten während meiner Zeit als Doktorand übernommen und dann auch noch die Kraft besessen hat, mich stets zu motivieren und zu unterstützen. Diese Dissertation war eine Reise mit Höhen und Tiefen. Für Ihren Einsatz, ihre Geduld und das aufgebrauchte Verständnis werde ich ihr ewig zutiefst dankbar sein.

Darmstadt, im Januar 2024.

# Inhaltsverzeichnis

<b>Vorwort</b> .....	<b>III</b>
<b>Inhaltsverzeichnis</b> .....	<b>IV</b>
<b>Formelzeichen- und Indexverzeichnis</b> .....	<b>VII</b>
<b>Abkürzungsverzeichnis</b> .....	<b>X</b>
<b>Abbildungsverzeichnis</b> .....	<b>XI</b>
<b>Tabellenverzeichnis</b> .....	<b>XIV</b>
<b>Kurzzusammenfassung</b> .....	<b>XV</b>
<b>Abstract</b> .....	<b>XVI</b>
<b>1 Einleitung</b> .....	<b>1</b>
1.1 Motivation .....	2
1.2 Aufbau der Arbeit .....	4
<b>2 Grundlagen</b> .....	<b>7</b>
2.1 Terminologie und Definitionen .....	7
2.2 Stand der Technik .....	13
2.2.1 Umfeldsensorik .....	13
2.2.2 Automatisierung von Metros und Vollbahnen .....	16
2.2.3 Assistenz und Automatisierung der Straßenbahn .....	18
2.3 Forschungsfragen .....	21
<b>3 Silent Testing als Methode</b> .....	<b>23</b>
3.1 Anforderungen an die Methode .....	23
3.2 Entwicklungswerkzeug Silent Testing .....	24
3.2.1 Grundlage Silent Testing .....	25
3.2.2 Existierende Silent Testing Methoden .....	26
3.3 Anwendung auf die Straßenbahn .....	29
3.3.1 Szenarien mit Abweichungen als Herausforderungen .....	29
3.3.2 Identifikation von relevanten Abweichungen .....	31
3.3.3 Parametrisierung $a_{krit}$ .....	35
3.3.4 Umsetzung der Methode im Rahmen dieser Arbeit .....	37

<b>4</b>	<b>Referenzarchitektur und -implementierung der Straßenbahnautomatisierung . . . .</b>	<b>40</b>
4.1	Funktionale Verhaltensanforderungen . . . . .	42
4.2	Referenzarchitektur . . . . .	46
4.2.1	Architekturgruppe <i>Sense</i> . . . . .	47
4.2.2	Architekturgruppe <i>Plan</i> . . . . .	50
4.2.3	Architekturgruppe <i>Act</i> . . . . .	52
4.3	Konkretisierung der Referenzarchitektur . . . . .	53
4.3.1	Nicht betrachtete Verhaltensanforderungen . . . . .	54
4.3.2	Objektdetektion . . . . .	55
4.3.3	Zustandserfassung Lichtsignalanlagen . . . . .	58
4.3.4	Verwendung der digitalen Karte . . . . .	58
4.3.5	Lokalisierung . . . . .	59
4.3.6	Einzelne Verhaltensplanung . . . . .	60
4.3.7	Auswahl des Verhaltens . . . . .	61
4.3.8	Zusammenfassung der Konkretisierung . . . . .	61
4.4	Referenzimplementierung . . . . .	62
4.4.1	Karte . . . . .	62
4.4.2	Lokalisierung . . . . .	68
4.4.3	Lidar Clustering . . . . .	69
4.4.4	2D Objektdetektor in Kamerabildern . . . . .	75
4.4.5	Fusion . . . . .	77
4.4.6	Zustandserfassung vorfahrtsregelnder Lichtsignalanlagen . . . . .	80
4.4.7	Verhaltensplanung: Berücksichtigung von Hindernissen . . . . .	83
4.4.8	Verhaltensplanung: Halt an Lichtsignalanlagen . . . . .	86
4.4.9	Verhaltensplanung: Halt an Haltestellen . . . . .	88
4.4.10	Verhaltensplanung: Höchstgeschwindigkeit . . . . .	88
4.4.11	Auswahl des Verhaltens und Berücksichtigung von Streckentrennern . . . . .	89
<b>5</b>	<b>Anwendung Silent Testing . . . . .</b>	<b>91</b>
5.1	$\mathcal{A}^-$ Lichtsignalanlagen . . . . .	94
5.1.1	$\mathcal{A}_{LSA}^-$ Makroskopische Betrachtung . . . . .	94
5.1.2	$\mathcal{A}_{LSA}^-$ Mikroskopische Betrachtung . . . . .	99
5.1.3	$\mathcal{A}_{LSA}^-$ Teilevaluation . . . . .	105
5.2	$\mathcal{A}^-$ Haltestellen . . . . .	107
5.2.1	$\mathcal{A}_{HS}^-$ Teilevaluation . . . . .	107

5.3	$\mathcal{A}^-$ Höchstgeschwindigkeit .....	108
5.3.1	$\mathcal{A}_{v_{\max}}^-$ Makroskopische Betrachtung .....	108
5.3.2	$\mathcal{A}_{v_{\max}}^-$ Mikroskopische Betrachtung .....	110
5.3.3	$\mathcal{A}_{v_{\max}}^-$ Teilevaluation .....	110
5.4	$\mathcal{A}^-$ Objekte .....	111
5.4.1	$\mathcal{A}_{\mathcal{O}}^-$ Makroskopische Betrachtung .....	112
5.4.2	$\mathcal{A}_{\mathcal{O}}^-$ Mikroskopische Betrachtung .....	123
5.4.3	$\mathcal{A}_{\mathcal{O}}^-$ Teilevaluation .....	145
5.5	$\mathcal{A}^+$ Abweichungen .....	149
5.5.1	$\mathcal{A}^+$ Makroskopische Betrachtung .....	150
5.5.2	$\mathcal{A}^+$ Mikroskopische Betrachtung .....	153
5.5.3	$\mathcal{A}^+$ Teilevaluation .....	162
<b>6</b>	<b>Fazit und Ausblick .....</b>	<b>166</b>
6.1	Fazit .....	166
6.2	Ausblick .....	170
<b>A</b>	<b>Annahmen und Herleitungen .....</b>	<b>172</b>
A.1	Mindestgeschwindigkeiten zur Identifikation einer Kreuzungsabsicht .....	172
A.2	ACC Regelung .....	172
<b>B</b>	<b>Details Abweichungen .....</b>	<b>174</b>
B.1	$\mathcal{A}^-$ Lichtsignalanlagen mit Detektion .....	174
B.2	$\mathcal{A}^-$ Lichtsignalanlagen ohne Detektion .....	175
B.3	$\mathcal{A}^-$ Höchstgeschwindigkeit .....	176
B.4	Klassifikation von Objekten ohne Abweichung .....	177
B.5	$\mathcal{A}_{\mathcal{O}}^-$ örtliche Hotspots .....	178
B.6	$\mathcal{A}_{\mathcal{O}}^-$ Fehldetektionen aufgrund der Sensornähe .....	179
B.7	$\mathcal{A}_{\mathcal{O}}^-$ aufgrund von Nebel .....	180
B.8	Abweichungen aufgrund fehlerhafter Intentionserkennung .....	181
B.9	Weitere Ursachen für $\mathcal{A}_{\mathcal{O}}^-$ .....	182
B.10	$\mathcal{A}_{v_{\max}}^+$ örtliche Hotspots .....	184
	<b>Literaturverzeichnis .....</b>	<b>185</b>
	<b>Eigene Publikationen .....</b>	<b>201</b>
	<b>Betreute Thesen .....</b>	<b>202</b>

# Formelzeichen- und Indexverzeichnis

## Lateinische Buchstaben

Zeichen	Einheit	Bezeichnung
$a$	$\frac{\text{m}}{\text{s}^2}$	Beschleunigung
$AP$	m	<i>Average Precision</i> , Gütemetrik Machine Learning
$d$	m	Distanz
$\vec{D}$	m	Position Drehgestell
$\vec{F}$	m	Position Faltenbalg
$h$	m	Höhe
$s$	-	Normierter Laufparameter Spline [0–1]
$t$	s	Zeit
$T$	s	Zeitpunkt
$v$	$\frac{\text{m}}{\text{s}}$	Geschwindigkeit
$x$	m	Position entlang der x-Achse eines Koordinatensystems
$y$	m	Position entlang der y-Achse eines Koordinatensystems

## Griechische Buchstaben

Zeichen	Einheit	Bezeichnung
$\beta$	°	Winkel benachbarter Lidarpunkte
$\tau$	s	Zeitkonstante der ACC-Regelung

## Kalligraphische Symbole und Frakturzeichen

Zeichen	Einheit	Bezeichnung
$\mathcal{A}$	-	Positive und Negative mit <i>Silent Testing</i> identifizierte Abweichungen
$\mathcal{G}$	-	Gruppenvergleichswert Hotspots
$\mathcal{O}$	-	Ein oder mehrere Objekte
$\mathcal{S}$	-	Ein oder mehrere Splines
$\mathcal{V}$	-	Anzahl aller Vorbeifahrten an einem Ort in den gesamt-heitlich aufgezeichneten Messdaten

## Indizes

Zeichen	Bezeichnung
akt	Aktuell
d	Distanz
det	Detektiert
ego	Egofahrzeug
Fahrer	Von Fahrer
flg	Folgend
FS	Fahrschlauch
GNSS	Basiert auf GNSS Messungen
halt	Halteabstand vor einem Objekt
HP	Haltepunkt
HS	Haltestelle
hspot	Hotspot
i	i-te Element einer diskreten Menge
j	h-te Element einer diskreten Menge
k	j-te Element einer diskreten Menge
krit	Kritischer Wert
LSA	Zur Lichtsignalanlage gehörig
max	Maximum
min	Minimum
mission	Mission des Fahrauftrage
N	Die Gesamtanzahl einer diskreten Menge
$\mathcal{O}$	Bezogen auf ein detektiertes oder getracktes Objekt
OuT	Von <i>Object under Test</i>
ref	Referenz
rel	Relativ
$\mathcal{S}$	Bezogen auf ein Spline der Karte
soll	Sollwert
tang	Tangential
track	Getrackt
v	Geschwindigkeit

## Akzente und Operatoren

<b>Zeichen</b>	<b>Bezeichnung</b>
$\vec{a}$	Vektor
$\hat{a}$	Schätzwert
$\tilde{a}$	Median
$\dot{a}$	1. Ableitung nach der Zeit
$\bar{a}$	Letzter bekannter Wert
$ a $	Betrag
$\Delta a$	Differenz

# Abkürzungsverzeichnis

ACC	Adaptive Cruise Control
ADMA	Automotive Dynamic Motion Analyzer
ATO	Automated Train Operation
BOStrab	Verordnung über den Bau und Betrieb der Straßenbahnen
BSSD	Behavior-Semantic Scenery Description
BÜ	Bahnübergang
CBTC	Communication Based Train Control
dPGS	Differential Global Positioning System
DZSF	Deutsches Zentrum für Schienenverkehrsforschung beim Eisenbahn-Bundesamt
eCDF	empirische kumulative Verteilungsfunktion
ENU	East-North-Up
FMCW	Frequency Modulated Continuous Wave
FoV	Field of View
GNSS	Global Navigation Satellite System
GoA	Grade of Automation
LSA	Lichtsignalanlage
MAAS	Machbarkeitsstudie zur Automatisierung und Assistenz der Straßenbahn
ODD	Operational Design Domain
ÖPNV	Öffentlicher Personennahverkehr
OuT	Object under Test
ROI	Region of Interest
RTK	Real Time Kinematic
SOTIF	Safety of the Intended Functionality
STPA	System-Theoretic Process Analysis
ToF	Time of Flight
<i>TTB</i>	Time To Brake
<i>TTC</i>	Time To Collision
UITP	Internationaler Verband für öffentliches Verkehrswesen
V2I	Vehicle to Infrastructure
VAAFO	Virtual Assessment of Automation in Field Operation
VDV	Verband deutscher Verkehrsbetriebe

# Abbildungsverzeichnis

Abbildung 2-4:	Kamera Verzeichnung. ....	14
Abbildung 2-5:	Nicht äquidistante Verteilung der Lidarebenen. ....	16
Abbildung 2-6:	Versuchsträger Siemens. ....	20
Abbildung 3-1:	VAAFO Architektur. ....	27
Abbildung 3-2:	Beispielhafter Zeitverlauf Beschleunigungsdifferenz. ....	32
Abbildung 3-3:	Beschleunigungsdifferenz mit kritischer Abweichung. ....	33
Abbildung 3-4:	Streuung von 85 Messungen bei Haltestelleneinfahrt. ....	36
Abbildung 3-5:	Boxplot der Streuung von Haltestelleneinfahrten. ....	36
Abbildung 3-6:	Sensorsetup und Komponenten des Versuchsfahrzeuges. ....	37
Abbildung 4-1:	Beispiele Grenzverhalten. ....	43
Abbildung 4-2:	Übergruppen Sense-Plan-Act der Referenzarchitektur. ....	47
Abbildung 4-3:	Referenzarchitektur Sense. ....	50
Abbildung 4-4:	Referenzarchitektur Plan. ....	52
Abbildung 4-5:	Referenzarchitektur Act. ....	53
Abbildung 4-6:	Konkretisierte Referenzarchitektur. ....	61
Abbildung 4-7:	Schematische Kartendarstellung mit Splines. ....	63
Abbildung 4-8:	Koordinatensysteme der Karte. ....	65
Abbildung 4-9:	Zusammenwirken Kinematik und Gleisverlauf. ....	66
Abbildung 4-10:	Ausschnitt der Karte mit visualisiertem Gierwinkel. ....	66
Abbildung 4-11:	$\beta$ zur Clusterbildung. ....	72
Abbildung 4-12:	Beschreibung der mittels Lidar detektierten Objektkontur. ....	73
Abbildung 4-13:	Beispielszene Lidar Clustering. ....	74
Abbildung 4-14:	YOLOv5 Beispielauswertung Kamerabilder. ....	76
Abbildung 4-15:	Beispielszene Zustandserfassung LSA. ....	82
Abbildung 4-16:	Bestimmung des Abstandes zu Objekten. ....	85
Abbildung 5-1:	Abweichungen beim Anfahren. ....	92
Abbildung 5-2:	Abweichungen ohne Detektion der LSA. ....	95
Abbildung 5-3:	Abweichungen LSA ohne Detektion bezogen auf die Vorbeifahren. ....	96
Abbildung 5-4:	eCDF Distanz LSA Abweichung mit Detektionen. ....	98
Abbildung 5-5:	Ausfälle der Detektion bei größerer Distanz. ....	100
Abbildung 5-6:	Beispielszenario I für Einfluss der Verzeichnung. ....	100
Abbildung 5-7:	Beispielszenario II für Einfluss der Verzeichnung. ....	101
Abbildung 5-8:	Beispielszenario für Anfahren trotz F0. ....	102
Abbildung 5-9:	Signal im Kamerabild nicht sichtbar. ....	103
Abbildung 5-10:	Beschleunigungsverlauf der einzigen Abweichung an Haltestellen. ....	107

Abbildung 5-11: eCDF aller 297 $\mathcal{A}_{v_{\max}}^-$ .....	108
Abbildung 5-12: Beschleunigungen OuT vs. Fahrer $\mathcal{A}_{v_{\max}}^-$ .....	109
Abbildung 5-13: Einordnung der Beschleunigungen bezüglich identifizierter $\mathcal{A}_{\bar{O}}$ .....	113
Abbildung 5-14: eCDF und Balkendiagramm der Objekthöhe. ....	114
Abbildung 5-17: $a_{\text{OuT}}$ über $a_{\text{Fahrer}}$ aller $\mathcal{A}_{\bar{O}}$ .....	119
Abbildung 5-18: Normierter Gruppenvergleich Hotspots $\mathcal{A}_{\bar{O}}$ .....	122
Abbildung 5-19: Ausschnitt Kartendarstellung $\mathcal{A}_{\bar{O}}$ Hotspots .....	123
Abbildung 5-20: Lidarsensorfehler Fahrgastunterstand. ....	124
Abbildung 5-21: $\mathcal{A}_{\bar{O}}$ durch Triebe eines Baums. ....	125
Abbildung 5-22: Verschiedene Formen der Vegetation lösen $\mathcal{A}_{\bar{O}}$ aus .....	126
Abbildung 5-23: $\mathcal{A}_{\bar{O}}$ durch Vegetation auf gepflastertem Boden .....	126
Abbildung 5-24: $\mathcal{A}_{\bar{O}}$ durch Straßennamensschild. ....	127
Abbildung 5-25: Beispiel für Versagen des Bodenfilters. ....	128
Abbildung 5-26: $\mathcal{A}_{\bar{O}}$ durch Versagen der Zustandsschätzung .....	130
Abbildung 5-27: Lidar Mehrwegreflexionen am nassen Boden. ....	131
Abbildung 5-28: $\mathcal{A}_{\bar{O}}$ mit langer Dauer aufgrund von Nebel. ....	132
Abbildung 5-29: Lidar Blooming an Verkehrsschildern. ....	133
Abbildung 5-30: Beispiel für Lidar Blooming bei Nässe .....	134
Abbildung 5-31: Beispiele für Fehlklassifikation und Fehlclustering von Objekten. ....	135
Abbildung 5-32: Beispiel für fehlende Trennfähigkeit des Lidar Clusterings .....	136
Abbildung 5-33: Beispiel I Versagen der Kreuzungsvorhersage. ....	138
Abbildung 5-34: Beispiel II Versagen der Kreuzungsvorhersage. ....	138
Abbildung 5-35: Beispiel I für Versagen aufgrund fehlender Intentionserkennung .....	139
Abbildung 5-36: Beispiel II für Versagen aufgrund fehlender Intentionserkennung .....	140
Abbildung 5-37: Beispiel kooperativer ÖPNV .....	141
Abbildung 5-38: Beispielszenario für den Einfluss der Reaktionszeiten. ....	142
Abbildung 5-39: Geschwindigkeitsregelung des menschlichen Fahrers .....	143
Abbildung 5-40: $\mathcal{A}_{v_{\max}}^+$ Verteilung Beschleunigungen. ....	150
Abbildung 5-41: Normierter Gruppenvergleich Hotspots $\mathcal{A}_{v_{\max}}^+$ .....	152
Abbildung 5-42: Ausschnitt Kartendarstellung $\mathcal{A}_{v_{\max}}^+$ Hotspots .....	153
Abbildung 5-43: Beispiel $\mathcal{A}_{\bar{O}}^+$ durch zu lange Fahrerreaktion .....	154
Abbildung 5-44: Beispiel I für fehlende Prädiktion. ....	156
Abbildung 5-45: Beispiel II für fehlende Prädiktion .....	156
Abbildung 5-46: Beispiel für fehlende Reaktion des OuT bei F4. ....	158
Abbildung 5-47: Beispiel $\mathcal{A}_{v_{\max}}^+$ durch Zurollen auf LSA. ....	159
Abbildung 5-48: F 1 statt F 0 wegen Sonneneinstrahlung. ....	160
Abbildung 5-49: Abweichungen durch belegte Haltestelle und Gleisarbeiten. ....	162
Abbildung B-1: Abweichungen LSA mit Detektion bezogen auf die Vorbeifahren. ....	174
Abbildung B-2: Domänenübergreifende LSA Herausforderungen I. ....	175

Abbildung B-3: Abweichung durch temporäre Geschwindigkeitsbeschränkung. ....	176
Abbildung B-5: Karte $\mathcal{A}_{\bar{0}}$ Hotspots. ....	178
Abbildung B-6: VLP-32C Lidarsensorfehler. ....	179
Abbildung B-7: Ibeo Scala Lidarsensorfehler. ....	179
Abbildung B-8: Übergang Nebel-effekt zwischen den beiden Sensoren. ....	180
Abbildung B-9: Anhäufung falscher Detektionen durch Nebel. ....	180
Abbildung B-10: Beispiel Versagen der Kreuzungsvorhersage. ....	181
Abbildung B-12: Radar Boundingboxen entgegenkommender Straßenbahn. ....	182
Abbildung B-13: Karte $\mathcal{A}_{v_{\max}}^+$ Hotspots. ....	184

# Tabellenverzeichnis

Tabelle 2-1: Zusammenfassung der GoA Stufen.....	17
Tabelle 3-1: Übersicht verbaute Umfeldsensoren.....	38
Tabelle 4-1: Funktionale Anforderungen basierend auf dem Grenzverhalten.....	45
Tabelle 4-2: Fehler a-priori bestimmte Orientierung.....	67
Tabelle 4-3: Vermessene punktuelle Infrastruktur.....	68
Tabelle 4-4: Klassenübersicht Kamera 2D Detektion.....	75
Tabelle 5-1: Identifizierte Abweichungen.....	93
Tabelle 5-2: Absolute Anzahl $\mathcal{A}_0^-$ pro Bodenkategorie.....	115
Tabelle 5-3: Ursachen $\mathcal{A}_0^-$ Hotspots.....	144
Tabelle 5-4: Identifizierte $\mathcal{A}^+$ .....	149
Tabelle A-1: Geschwindigkeiten Klassifikation kreuzender Objekte.....	172

## Kurzzusammenfassung

Die Automatisierung von verschiedenen Fahrzeugen schreitet voran, wobei sich das Forschungs- und Entwicklungsfeld im Bereich der Straßenbahn als vergleichsweise jung erweist. Die Automatisierung von Straßenbahnen erscheint oberflächlich betrachtet aufgrund systemimmanenter Vorteile wie der Spurbindung als vereinfacht, während sie gleichzeitig durch andersartige Herausforderungen, bspw. in Bezug auf die Nähe zu Passanten in Fußgängerzonen, gegenüber der Automatisierung von Kraftfahrzeugen erschwert wird. Zur systematischen und gezielten Entwicklung der Automatisierung sind diese andersartigen Herausforderungen und neuartigen Möglichkeiten zur Vereinfachung der Automatisierungsaufgabe von Straßenbahnen zu identifizieren.

Im Rahmen dieser Arbeit wird eine Methode zur wissenschaftlichen Identifikation dieser Herausforderungen und Möglichkeiten entwickelt, die den bestehenden Ansatz des *Silent Testing* für Straßenbahnen erweitert. Diese Methodik ermöglicht die Ausführung einer Automatisierung als passives Schattensystem, bei dem keine direkten Eingriffe in die Fahrzeugsteuerung erfolgen und das Fahrzeug weiterhin von einem menschlichen Fahrer gesteuert wird. Zu diesem Zweck ist eine bestehende Straßenbahn mit Umfeldsensorik und Auswertecomputern umgerüstet und trotz dieser Änderungen weiterhin im regulären Linienbetrieb mit menschlichem Fahrer betrieben worden. Die Daten der Umfeldsensoren werden aufgezeichnet und im Anschluss mit einer im Rahmen dieser Arbeit entwickelten Software zum automatisierten Fahren von Straßenbahnen ausgewertet.

Da bisher keine Beschreibung des Funktionsumfangs eines solchen Automatisierungssystems für Straßenbahnen vorliegt, werden in dieser Arbeit erstmalig Verhaltensanforderungen und eine Referenzarchitektur als erster Vorschlag erarbeitet. Die Architektur wird durch neuartige Möglichkeiten zur Vereinfachung der Automatisierungsaufgabe konkretisiert und umgesetzt. Die Auswertung der Messdaten durch das implementierte Automatisierungssystem führt zu einem geplanten Soll-Verhalten der Automatisierung für jeden aufgezeichneten Zeitschritt. Dieses Verhalten wird mit dem tatsächlich umgesetzten Verhalten des menschlichen Fahrers verglichen.

Durch den Vergleich von menschlichem und maschinellm Verhalten ergeben sich Abweichungen, bei denen es sich unter anderem um andersartige Herausforderungen der Automatisierung von Straßenbahnen handelt. Gleichzeitig erfolgt eine Plausibilisierung der neuartigen Möglichkeiten, sofern keine identifizierten Abweichungen auf diese Möglichkeiten als Ursache zurückzuführen sind. Die Ergebnisse dieser Arbeit umfassen die Identifikation und Beschreibung mehrerer straßenbahnspezifischer Herausforderungen und Möglichkeiten zur Vereinfachung der Automatisierungsaufgabe. Zudem werden Stärken und Schwächen des *Silent Testing* im urbanen Einsatz identifiziert, die teilweise auch auf die Automatisierung von Kraftfahrzeugen übertragen werden könnten.

## Abstract

The automation of various vehicles is progressing, with the research and development field in the tram sector proving to be relatively young. From a high-level point of view, the automation of trams appears simplified due to inherent advantages such as track binding, while simultaneously being complicated by distinctive challenges, for instance, proximity to passersby in pedestrian zones, in contrast to the automation of motor vehicles. In order to systematically and purposefully advance automation, these distinctive challenges and opportunities for simplifying tram automation tasks need to be identified.

Within this work, a method for the scientific identification of these challenges and opportunities is developed, expanding upon the existing approach of *Silent Testing* for trams. This methodology enables the execution of automation as a passive shadow system, wherein there are no direct interventions in the vehicle control, and the vehicle continues to be operated by a human driver. For this purpose, an existing tram is retrofitted with environmental sensors and evaluation computers.

However, despite these changes, the tram persisted in its routine operation, transporting passengers while being driven by a regular human driver. The data from the environmental sensors are recorded and subsequently evaluated with software developed within the scope of this thesis for the automated driving of trams.

Since there is currently no description of the functionality of such an automation system for trams, this work establishes, for the first time, behavioral requirements and a reference architecture as an initial proposal. The architecture is concretized through novel opportunities to simplify the automation task and is implemented in practice. The evaluation of measurement data by the implemented automation system results in a planned target behavior for automation at each recorded time step. This behavior is compared with the actual behavior of the human driver.

Comparisons of human and machine behavior reveal discrepancies, representing, among other things, distinctive challenges in the automation of trams. Simultaneously, a plausibility check of the novel possibilities is conducted, provided that identified deviations cannot be attributed to these possibilities as the cause. The results of this study encompass the identification and description of several tram-specific challenges and opportunities to simplify the automation task. Additionally, strengths and weaknesses of *Silent Testing* in urban deployment are identified, some of which could potentially be extrapolated to the automation of motor vehicles.

# 1 Einleitung

Die Bestrebung, Fahrzeuge des Straßenverkehrs zu automatisieren, besteht bereits seit längerer Zeit. In der Vergangenheit forschten Dickmanns et al.<sup>1</sup> bereits in den 1980er Jahren am automatisierten Fahren und bauten hierfür ein Versuchsfahrzeug auf, welches sich unter Verwendung von Kameras und maschineller Bildauswertung eigenständig bewegen konnte. Insbesondere seit den Erfolgen der DARPA Challenges<sup>2</sup> rückte das automatisierte Fahren in den Fokus der Öffentlichkeit und wurde unter dem Erreichen verschiedener Meilensteine<sup>3, 4, 5, 6</sup> stets weiterentwickelt. Die Entwicklung automatisierter Fahrfunktionen ist seitdem ein wesentlicher Bestandteil der Fahrzeugentwicklung.

Dabei ist die Motivation zur Automatisierung von Fahrzeugen des Straßenverkehrs vielfältig. Insbesondere langfristig wird ein Zugewinn an Sicherheit durch eine Reduktion von Unfällen und deren Schwere erwartet, wie es bereits heute Assistenzsysteme als Vorläufer der Automatisierung bewirken.<sup>7a</sup> Weitere antizipierte Vorteile der Automatisierung sind der Zugewinn an Reisekomfort oder die Verbesserung zur Teilhabe am gesellschaftlichen Leben für eingeschränkte Personen.<sup>8</sup> Neben der reinen Personenbeförderung kann die Automatisierung auch für den Güterverkehr von Bedeutung sein. So kann die Automatisierung im Gütertransport die Wirtschaftlichkeit der Logistikbranche steigern und gleichzeitig die Dynamik von Lieferketten erhöhen.<sup>9a</sup>

Im öffentlichen Personennahverkehr bietet die Automatisierung das Potenzial die Attraktivität des Beförderungsangebotes zu steigern. So kann die Wirtschaftlichkeit gesteigert werden, indem bspw. mehr Fahrten zu Randzeiten sowie Randgebieten ermöglicht werden, und gleichzeitig ist davon auszugehen, dass die Mobilität kosteneffizienter angeboten werden kann.<sup>10</sup> Darüber hinaus existiert im Bereich des ÖPNV ein stetig wachsender Mangel an Fahrpersonal,<sup>11</sup> der durch eine Automatisierung abgemildert werden kann.

---

1 Dickmanns, E. D.; Zapp, A.: Autonomous High Speed Road Vehicle Guidance (1987).

2 Buehler, M. et al.: The DARPA Urban Challenge (2009).

3 Ziegler, J. et al.: Making Bertha Drive (2014).

4 Schwall, M. et al.: Waymo Safety Performance Data (2020), S. 1.

5 KBA: PM erste Genehmigung zum automatisierten Fahren (2021).

6 Jin, H. et al.: Cruise & Waymo win permits (2021).

7 Bengler, K. et al.: FAS und Automatisiertes Fahren (2021), a: S. 1011, 1054 ff., b: S. 1054.

8 Dangschat, J. S.: Automatisierter Verkehr – was kommt da auf uns zu? (2017), S. 497.

9 Maurer, M. et al.: Autonomes Fahren (2015), a: S. 390, b: S. 388.

10 Niemann, J. et al.: VDV Innovationspapier Automatisierte Personenbeförderung (2021), S. 6.

11 VDV: Personalumfrage im ÖV (2023).

## 1.1 Motivation

Obwohl Assistenzsysteme fortwährend zunehmend komplexe Teilaufgaben übernehmen, resultiert die Gesamtheit aller konzipierten Assistenzsysteme, selbst in weiterentwickelten Ausführungen, nicht zwangsläufig in einer fahrerlosen Automatisierung. Obgleich können bestehende funktionale Ansätze der Assistenzsysteme auch bei der Automatisierung Anwendung finden, jedoch ist dies keine hinreichende Bedingung zur Erfüllung der Fahraufgabe.

Im Rahmen der Assistenzsysteme fungiert der Mensch kontinuierlich als integraler Bestandteil der Regelstrecke. Um die Falsch-Positiv-Rate zu reduzieren, d. h. das irrtümliche Auslösen eines Assistenzsystems, besteht die Möglichkeit, beispielsweise die Auslöseschwellen des Systems zu verringern. Eine solche Anpassung geht jedoch zwangsläufig mit einer Zunahme der Falsch-Negativ-Rate einher, d. h. dem Versäumnis des Auslösens trotz bestehendem Bedarf. Der Mensch kann im Rahmen der Assistenz diese Lücke schließen, indem er situationsspezifisch einen Handlungsbedarf erkennt und diesen Teil der Fahraufgabe ergänzend übernimmt. Im Kontrast dazu fehlt beim automatisierten Fahren der Mensch, der eine korrigierende Funktion übernehmen könnte, und gleichzeitig ist das Auftreten von falsch negativen sowie kritischen falsch positiven Ereignissen — in beiden Fällen potenzielle Unfälle — nicht tolerierbar.<sup>7b</sup>

Aufgrund der Vielzahl an zu lösenden Herausforderungen (Umfeldperzeption, Antizipation des Verhaltens anderer Verkehrsteilnehmer in einer komplexen Umgebung etc.) stellt die zielgerichtete Entwicklung von fahrerlosen Fahrfunktionen eine Pionierarbeit dar. Für die Entwicklung von Fahrfunktionen ist eine Identifikation von noch zu lösenden Herausforderungen erforderlich. Ein Teilgebiet der Forschung zum automatisierten Fahren setzt genau hier an: Um den Testaufwand für den notwendigen Sicherheitsnachweis zu reduzieren, werden gezielt geeignete Testszenarien gesucht.<sup>12, 13</sup> Da sich die Fahrzeuge des Straßenverkehrs jedoch in einer offenen und somit unvorhersehbaren komplexen Welt bewegen, ist es nicht möglich alle denkbaren Szenarien zu definieren oder gar rein theoretisch abzuleiten. In der ISO 2144, welche sich mit der *Safety of the Intended Functionality* (SOTIF) beschäftigt, wird explizit die Anwesenheit von unbekanntem Situationen adressiert. Dabei ist, vereinfacht ausgedrückt, ein Teilziel der SOTIF die Wahrscheinlichkeit der Existenz von unbekanntem und potenziell gefährlichen Situationen modellbasiert durch Verifikation und Validierung zu reduzieren.<sup>14</sup>

Hinzu kommt, dass mit steigender Komplexität der zu automatisierenden Fahraufgabe auch die Anzahl und Komplexität der zu erfüllenden Anforderungen steigt. Seit 2021 ist eine erste kommerzielle Lösung zur Automatisierung in Stausituationen auf deutschen Autobahnen zugelassen: „Es handelt sich dabei um einen automatisierten Modus, bei dem der Fahrer das System nicht dauernd überwachen muss“.<sup>5</sup> Das System darf also nur in bestimmten Situationen

---

12 Bach, J. et al.: Model based scenario specification (2016).

13 Neurohr, C. et al.: Considerations around Scenario-Based Testing (2020).

14 ISO 21448: SOTIF (2022), S. 14.

eingesetzt werden und grundsätzlich muss der Mensch nach einer Übernahmeaufforderung durch das System stets in der Lage sein, die Fahraufgabe zu übernehmen. Für den deutlich komplexeren urbanen Raum, in dem auch die Automatisierung von Straßenbahnen stattfinden soll, gibt es noch keine breitflächige kommerzielle Lösung. Lediglich die Alphabet Tochter Waymo und das zu General Motors zugehörige Unternehmen Cruise haben im August 2023 eine Zulassung für einen kommerziellen Taxibetrieb mit autonomen Fahrzeugen erhalten.<sup>15</sup> Dabei beschränkt sich diese Erlaubnis nur auf die Stadt San Francisco. Wegen Zwischenfällen ist diese jedoch für Cruise bereits im Oktober 2023 wieder ausgesetzt worden.<sup>16</sup> Zusätzlich ist zu beachten, dass es sich bei diesem einzigen kommerziellen Angebot in San Francisco auch nur um eine einzige Stadt handelt. Darüber hinaus existieren weltweit mehrere Testprojekte zu autonomen Taxis, bei denen es sich um Versuchsfahrten mit und ohne anwesenden Sicherheitsfahrer handelt.<sup>17, 18</sup> Bezüglich automatisiert fahrender Straßenfahrzeuge gibt es somit bisher nur vereinzelte Anwendungen. Dabei wartet insbesondere der städtische Verkehr mit einer Vielzahl an weiteren unbekanntem Herausforderungen auf. Diese Anforderungen können wie oben beschrieben zwar nicht vollständig erfasst werden, es gilt jedoch diese Wissenslücke der unbekanntem Anforderungen zu minimieren.

Neben der Gewährleistung der Sicherheit und dem entsprechenden Nachweis spielen diese unbekanntem Anforderungen bereits in frühen Phasen des Entwicklungsprozesses eine entscheidende Rolle bei der systematischen Berücksichtigung einzelner Funktionen. Während Teile der Anforderungen zwar aus Gesetzen, Ordnungen und Allgemeinwissen a-priori abgeleitet werden, können hierbei funktionale Anforderungen übersehen und insbesondere die Komplexität der realen Welt nicht ausreichend berücksichtigt werden. Letzteres impliziert insbesondere die technischen Herausforderungen, also Probleme bei Erfüllung gestellter Anforderungen. Daher bedarf es zusätzlich zu theoretisch abgeleiteten Anforderungen auch eines praktischen Weges, um den Reifegrad von Automatisierungen abprüfen zu können bzw. Anforderungen und Probleme bei der Implementierung solcher Algorithmen früh im Entwicklungsprozess zu identifizieren.

Während die Automatisierung von Kraftfahrzeugen, Lastkraftwagen<sup>9b</sup> und auch Bussen<sup>19</sup> seit Jahrzehnten vorangetrieben wird, ist die Automatisierung von Straßenbahnen als Mischform des Straßen- und Schienenverkehrs ein junges Forschungs- und Entwicklungsgebiet. So gibt es erst seit 2014 einfache Kollisionswarnsysteme<sup>20</sup> und seit 2017/18 erste Projekte<sup>21, 22</sup> zur Entwicklung und Erforschung der Automatisierung. Dazu zählt das Forschungsprojekt *Machbarkeitsstudie*

---

15 CPUC: Permits for Cruise and Waymo (2023).

16 DMV: Statement on Cruise LLC Suspension (2023).

17 China Daily: Guideline unveiled (2023).

18 DMV: Autonomous Vehicle Testing Permit Holders (2023).

19 Ainsalu, J. et al.: Sota Automated Buses (2018).

20 Bosch: PM Beifahrer für Straßenbahnen (2016).

21 Palmer, A. W. et al.: The Autonomous Siemens Tram (2020).

22 HEAG: Forschungs-Straßenbahn vorgestellt (2019).

zur *Automatisierung und Assistenz der Straßenbahn* (MAAS), welches die Grundlage für diese Arbeit bildet. Da Straßenbahnen insbesondere im öffentlichen Verkehrsraum nicht mit einer Zugsicherung verkehren, müssen sie wie Kraftfahrzeuge ihr Umfeld dezentral erfassen und die Fahraufgabe eigenständig lösen. Aus diesem Grund liegt es nahe, Schlüsseltechnologien sowie bestehende technische Lösungsansätze aus den Bestrebungen zur Automatisierung von Kraftfahrzeugen auf die Straßenbahn zu übertragen.

Da Straßenbahnen im Gegensatz zu Kraftfahrzeugen einerseits auf Schienen und andererseits stellenweise abseits von Straßen sowie in besonderen Umgebungen wie Fußgängerzonen verkehren, sind dabei straßenbahnspezifische Anforderungen und Herausforderungen zu erwarten. Bspw. stellt sich die Frage, ob übliche Sensoren des automatisierten Fahrens wie Kameras, Radar und Lidar auch für die Automatisierung von Straßenbahnen in gleicher Güte geeignet sind. Dabei gibt es andersartige Randbedingungen wie ein offenes und somit unebenes Gleisbett oder die Nähe zu Passanten, die aufgrund der Spurbundenheit teilweise sehr nah am Lichtraumprofil der Bahn stehen.

Während in der Literatur technische Lösungen und Probleme bei der Automatisierung von Kraftfahrzeugen bereits ausführlich diskutiert werden, ist Literatur zur Automatisierung von Straßenbahnen und denen damit verbundenen neuen Problemstellungen kaum vorhanden. Diese Wissenslücke zieht sich durch alle technischen Verarbeitungsschritte einer Automatisierung: Die Übertragbarkeit von im Kraftfahrzeugbereich etablierten Sensoren und deren Auswertemethoden sind genauso ungewiss wie darauf aufbauende Algorithmen zur Verhaltensplanung.

Im Rahmen dieser Arbeit wird eine Methode vorgestellt, die Realdaten nutzt, um Herausforderungen bei der Automatisierung von Fahrzeugen praktisch zu identifizieren sowie eine Plausibilisierung von neu konzipierten Lösungsansätzen zu ermöglichen. Dabei wird das Fahrzeug weiterhin mit menschlichem Fahrer in seiner Realumgebung betrieben und die Automatisierung als Schattensystem eingesetzt. Anhand einer ersten vereinfachten Automatisierung für Straßenbahnen wird diese Methode angewendet und so die Übertragbarkeit von Automatisierungsansätzen aus dem Kraftfahrzeugbereich auf die Straßenbahn untersucht. Auf diese Weise werden die wesentlichen Probleme der Automatisierung von Straßenbahnen aufgezeigt und gleichzeitig straßenbahnspezifische Möglichkeiten überprüft, die zur Vereinfachung der Automatisierungsaufgabe in ein Schattensystem integriert sind.

## 1.2 Aufbau der Arbeit

Um ein umfassendes Verständnis zu erleichtern und einen Einblick über das Zusammenwirken der einzelnen Abschnitte zu bieten, wird im folgenden Unterkapitel die Struktur der vorliegenden Arbeit erörtert. Hierbei erfolgt eine knappe Skizzierung des Inhalts jedes Kapitels. Die grundle-

gende Gliederung der Arbeit ist in Abbildung 1-1 veranschaulicht und wird im Anschluss näher erläutert.

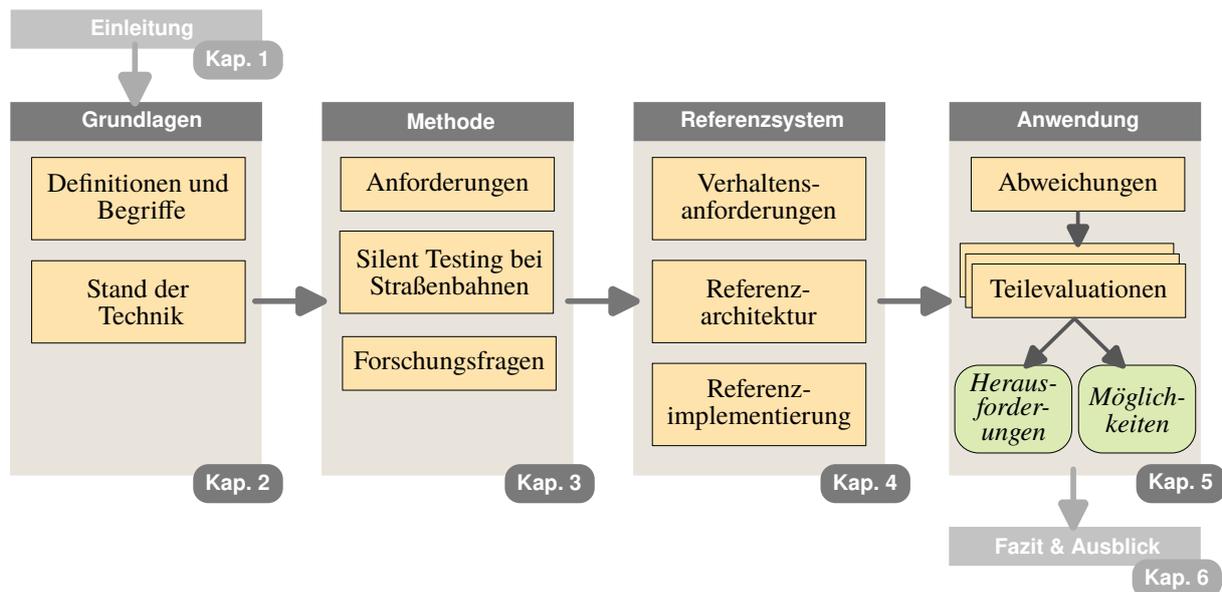


Abbildung 1-1: Aufbau und Struktur der Arbeit.

Im anschließenden Kapitel 2 erfolgt neben allgemeinen **Grundlagen** zum weiteren Verständnis dieser Arbeit eine **Definition** verschiedener Begrifflichkeiten sowie ein Überblick über den **Stand der Technik** bezüglich automatisiertem Fahren von Straßenbahnen und Sensoren zur Umfeld-erfassung. Aufgrund ihrer Vorreiterrolle werden dabei Sensoren aus dem Kraftfahrzeugbereich betrachtet.

Zur Identifikation von Herausforderungen und Plausibilisierung neuartiger Möglichkeiten der Automatisierung von Straßenbahnen wird in Kapitel 3 eine Methodik auf der Basis des nachfolgend erläuterten *Silent Testing* entworfen. Dabei werden eingangs **Anforderungen** an die Methode definiert und der Stand der Technik bezüglich *Silent Testing* identifiziert. Dieser wird bezüglich der Übertragbarkeit vom Kraftfahrzeug eingeordnet und für eine Anwendung von **Silent Testing bei Straßenbahnen** angepasst. Da im Rahmen dieser Arbeit *Silent Testing* erstmals im Bereich der Straßenbahn angewendet wird sowie verglichen mit dem Kraftfahrzeugbereich das junge Forschungsgebiet der Automatisierung von Straßenbahnen viele Unbekannte aufweist, werden strukturleitende **Forschungsfragen** erarbeitet.

Bei der Anwendung der erarbeiteten Methode handelt es sich um einen experimentellen Forschungsansatz mittels Vergleich zwischen Mensch und Maschine. Aus diesem Grund bedarf es neben einer vom Menschen gefahrenen Straßenbahn mit Sensoren zusätzlich einem Automatisierungssystem. Da es letzteres bisher nicht gibt, wird im Rahmen dieser Arbeit ein Automatisierungssystem prototypisch umgesetzt. Für ein strukturiertes Vorgehen werden dazu in Kapitel 4 aus verschiedenen Quellen **Verhaltensanforderungen** als notwendiges Sollverhalten einer automatisierten Straßenbahn abgeleitet. Basierend auf diesen Anforderungen wird eine

allgemeine **Referenzarchitektur** zur Automatisierung von Straßenbahnen entworfen und für die praktische Anwendung im Rahmen dieser Forschungsarbeit konkretisiert sowie als umgesetztes Automatisierungssystem im Unterkapitel der **Referenzimplementierung** beschrieben. Im Rahmen der Architektur und der Implementierung werden neuartige Möglichkeiten der Automatisierung adressiert, die sich mit der Domäne Straßenbahn und ihrem beschränkten Einsatzgebiet sowie der Spurbindung ergeben.

Die zuvor in Kapitel 3 abgeleitete Methodik wird mit dem in Kapitel 4 beschriebenen Automatisierungssystem auf aufgezeichneten Realfahrten der Straßenbahn in Kapitel 5 angewendet. Dabei werden **Abweichungen** zwischen Mensch und Automatisierungssystem sowohl makroskopisch mit einer statistischen Auswertung als auch anhand einzelner Messreihen mikroskopisch analysiert. Im Rahmen verschiedener **Teilevaluationen** werden die mittels *Silent Testing* identifizierten Abweichungen bezüglich spezifischer Herausforderungen sowie neuartiger Möglichkeiten der Automatisierung von Straßenbahnen bewertet.

Abschließend fasst Kapitel 6 die Forschungsergebnisse zusammen und gibt einen Ausblick auf weiterführende Forschungsrichtungen.

## 2 Grundlagen

In diesem Kapitel werden Grundlagen für den weiteren Verlauf dieser Arbeit erläutert. Einerseits werden dazu nachfolgend Begriffe definiert und abgegrenzt, andererseits wird der Stand der Technik bezüglich der Automatisierung sowie den in dieser Arbeit eingesetzten Umfeldsensoren aufgezeigt.

### 2.1 Terminologie und Definitionen

#### **Straßenbahnen**

In Deutschland sind der Bau und Betrieb von Straßenbahnen durch die sogenannte „Verordnung über den Bau und Betrieb der Straßenbahnen (BOStrab)“<sup>23a</sup> geregelt. Jedoch fallen nach BOStrab § 1 auch unabhängige Bahnen, die „auf der gesamten Streckenlänge vom Straßenverkehr oder anderen Verkehrssystemen getrennt“<sup>23b</sup> sind, unter den Begriff Straßenbahn. Dies umfasst also auch U-Bahnen, Hochbahnen, Metros etc. Zur Abgrenzung werden in dieser Arbeit unter dem Begriff Straßenbahnen ausschließlich solche Bahnsysteme aufgefasst, die mehrheitlich im öffentlichen und nicht in einem eigenen Verkehrsraum betrieben werden.

Insbesondere vollständig vom öffentlichen Verkehrsraum abgetrennte Bahnsysteme des Stadtverkehrs werden nachfolgend als Metro bezeichnet. Mit Vollbahnen hingegen werden entsprechend der DIN 17343 konventionelle Eisenbahnen für den regionalen wie auch internationalen Verkehr bezeichnet.<sup>24</sup>

#### **Automatisierung**

Der Begriff Automatisierung wird in dieser Arbeit im Sinne der Fahraufgabe und dem damit verbunden Führen eines Fahrzeuges verwendet. Für Straßenbahnen ist die Fahrt im Linienbetrieb mit Fahrgästen gemeint, nicht jedoch der gesamtheitliche Betrieb sowie die damit verbundenen weiteren Aufgaben des Fahrers wie z. B. die Überwachung des Fahrgastraums oder übergeordnete Abläufe wie die Disposition von automatisierten Fahrzeugen.

Sofern im weiteren Verlauf der Arbeit nicht ausdrücklich anders erwähnt, bezieht sich das automatisierte Fahren von Straßenbahnen auf einen fahrerlosen Betrieb im öffentlichen Straßenraum, ohne eine dauerhafte menschliche Überwachung der Automatisierung. Für Straßenbahnen

---

23 BGBl: BOStrab (1987), a: -, b: § 1, c: § 16 Abs. 4.

24 DIN EN 17343: Bahnanwendungen – Allgemeine Begriffe (2022).

(im obigen Sinne) gibt es keine eigene Norm oder Einteilung für den Funktionsumfang einer Automatisierung.

Als verwandte Domäne sind für Metros die sogenannten *Grade of Automation (GoA)* 0–4 nach IEC / DIN EN 62290<sup>25, 26</sup> definiert, auf die im weiteren Verlauf in Kapitel 2.2.2 eingegangen wird. Die Einteilung bezieht sich zwar auf den Betrieb von Metros mit eigenen Verkehrsräumen, ist jedoch grundsätzlich auf den Straßenbahnverkehr übertragbar. Dabei ist zu beachten, dass die zugrunde liegenden Kategorien der Einteilung wie *Sichern des Fahrweges* bereits bei GoA 1 erfüllt werden und bei Metros aufgrund des eigenen Verkehrsraums signifikant einfacher als bei Straßenbahnen zu erreichen sind. Das mit der Automatisierung von Metros üblicherweise verbundene System zu *Automated Train Operation (ATO)* leitet aus der zentralen Zugbeeinflussung die Fahr- und Bremsbefehle ab. Im Gegensatz dazu erfolgt auch bei einer automatisierten Straßenbahn innerhalb des öffentlichen Verkehrsraums die dezentrale Bestimmung von Fahrfreigaben, wie es näher in Kapitel 4 beschrieben wird. Vor diesem Hintergrund muss beachtet werden, dass die Unterscheidung der Stufen für den Straßenbahnverkehr nicht die Komplexität der Automatisierung ausdrückt. Da jedoch im Rahmen dieser Arbeit die Automatisierung von Straßenbahnen im öffentlichen Verkehrsraum ohne Betriebspersonal im Fahrzeug betrachtet wird, entspricht die hier untersuchte Automatisierung GoA 4.

Im Kraftfahrzeugbereich erfolgt die Einteilung von Automatisierungsstufen mehrheitlich nach SAE J3016.<sup>27</sup> Level 0 entspricht dabei keinerlei Assistenz bezüglich der dynamischen Fahraufgabe, während Level 5 einer vollständigen Automatisierung in allen Bereichen und Szenarien ohne jegliche Einschränkungen entspricht. Da nachfolgend nur die Automatisierung im Fahrgastbetrieb und nicht bspw. die Automatisierung des Rangierens betrachtet wird, entspricht die hier betrachtete Automatisierung der Straßenbahn sinngemäß Level 4 nach SAE J3016.

### **Straßenbündige, besondere und unabhängige Bahnkörper**

Die BOStrab unterscheidet drei verschiedene Bahnkörper, die im weiteren Verlauf dieser Arbeit zur Beschreibung genutzt werden. *Straßenbündige* Bahnkörper teilen sich den Verkehrsraum mit anderen Verkehrsteilnehmern und sind in Fahrbahnen oder Gehwegen eingelassen. *Besondere* Bahnkörper liegen zwar auch im öffentlichen Verkehrsraum, sind jedoch von der Fahrbahn durch Bordsteine oder andere bauliche Elemente abgetrennt. *Unabhängige* Bahnkörper sind vollständig vom öffentlichen Verkehrsraum getrennt.<sup>23b</sup>

Nachfolgende Abb. 2-1 zeigt exemplarisch die drei verschiedenen Bahnkörper. Neben dieser Einteilung weisen alle drei Bahnkörper zusätzlich verschiedene Bodenuntergründe auf. So kann bspw. ein *besonderer* Bahnkörper entweder gepflastert, mit Gras bewachsen oder auf andere Weise bedeckt sein.

---

25 DIN EN 62290: Betriebsleit- und Zugsicherungssysteme (2015).

26 Ursprünglich nach Internationaler Verband für öffentliches Verkehrswesen (UITP).

27 SAE J3016: Taxonomy and Definitions (2021).



(a) Straßenbündiger Bahnkörper

(b) Besonderer Bahnkörper

(c) Unabhängiger Bahnkörper

Abbildung 2-1: Beispiele für die drei verschiedenen Bahnkörper.

## Szene und Szenario

Im Rahmen dieser Arbeit werden die Begriffe Szene und Szenario verwendet. Dabei folgen diese Begrifflichkeiten der im öffentlichen Straßenverkehr etablierten Definition nach Ulbrich et al.<sup>28, 29a</sup>

**Szene:** „Eine Szene beschreibt eine Momentaufnahme des Umfelds, welche die Szenerie, dynamische Elemente, die Selbstrepräsentation aller Akteure und Beobachter wie auch die Verknüpfung dieser Entitäten umfasst. Einzig eine Szenenrepräsentation in einer simulierten Welt kann allumfassend sein (objektive Szene, Ground Truth). In der realen Welt ist sie immer unvollständig, fehlerbehaftet, unsicherheitsbehaftet und aus der Perspektive eines oder mehrerer Beobachter (subjektive Szene).“<sup>29b</sup>

**Szenario:** „Ein Szenario beschreibt die zeitliche Entwicklung von Szenenelementen innerhalb einer Folge von Szenen, welche mit einer Startszene beginnt. Aktionen und Ereignisse ebenso wie Ziele und Werte können spezifiziert werden, um diese zeitliche Entwicklung in einem Szenario festzulegen. Im Gegensatz zu Szenen decken Szenarien eine gewisse Zeitspanne ab.“<sup>29c</sup>

## Individualverkehr

Der Individualverkehr stellt das Gegenstück zum klassischen ÖPNV dar und umfasst alle Verkehrsteilnehmer, die außer Fahrzeugen des ÖPNV im öffentlichen Verkehr unterwegs sind. Dazu zählen neben dem motorisierten Individualverkehr auch Fußgänger, Radfahrer und andere Verkehrsteilnehmer.

## Lichtsignalanlage

Im Rahmen dieser Arbeit wird unter dem Begriff Lichtsignalanlage (LSA) der Signalgeber, umgangssprachlich meist Ampel genannt, einer stationären Einrichtung verstanden, die mittels

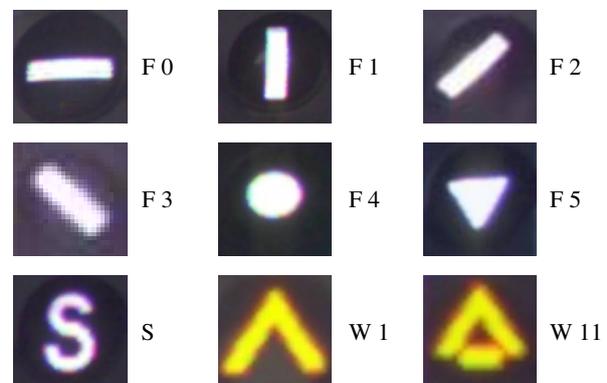
28 Ulbrich, S. et al.: Defining the Terms Scene, Situation, and Scenario (2015).

29 Ulbrich, S. et al.: Definition der Begriffe Szene, Situation und Szenar (2015), a: -, b: S. 2, c: S. 10.

Wechsellichtzeichen den Verkehr beeinflusst. Je nach Ausführung ist diese für Straßenbahnen oder Teile des Individualverkehrs gültig. Nach BOStrab sind weder die Begriffe Lichtsignalanlage noch Wechsellichtzeichen definiert. Im weiteren Verlauf dieser Arbeit werden daher neben den Einrichtungen des Individualverkehrs unter einer LSA sämtliche Einrichtungen zur Anzeige von Signalen der BOStrab aufgefasst, die auf Wechsellichtzeichen basieren. Dazu zählen bspw. die Vorfahrtregelung mit F 0–5 oder die Anzeige der Weichenlage mit W 1–4 bzw. W 11–41. Als Signalfelder werden im Folgenden die Elemente der LSA bezeichnet, die ein einzelnes Signal anzeigen. Abb. 2-2 (a) zeigt beispielhaft die Unterschiede zwischen LSA und Signalfeld. Die Bedeutung der Signale wird in Kap. 4 näher erläutert. Als wichtige Signale gelten jedoch F 0, welches einen Halt gebietet, F 1–3 welche die Fahrt entsprechend der Richtung des Balkens freigeben sowie F 4 welches ein nachfolgendes Signal F 0 ankündigt und damit das Pendant zur Gelbphase im Individualverkehr darstellt. Abb. 2-2 (b) zeigt beispielhaft verschiedene Signalfelder von LSA.



(a) Neben dem markierten Signalfeld sind zwei Signalfelder aus und eines zeigt „S“, um dem Fahrer zu signalisieren, dass eine funkbasierte Anforderung zur Freigabe erfolgt ist.



(b) Beispiele für verschiedene Signale der LSA. Nach BOStrab gibt es weitere Signale. Die Beachtung und Bedeutung der Signale wird in Kap. 4 näher erläutert.

Abbildung 2-2: Übersicht LSA und Signalfelder.

## Operational Design Domain

Diese Arbeit folgt der oben beschriebenen SAE J3016<sup>27</sup> zur Definition einer *Operational Design Domain* (ODD). Demnach ist die ODD derjenige Bereich, für welchen die Funktionen der Automatisierung ausgelegt sind. Dabei beschreibt ODD nicht zwangsläufig einen festen räumlichen Bereich, sondern vielmehr die Anforderungen an diesen, wie z.B. Bodenuntergründe, Vorhandensein von LSA etc. Darüber hinaus legt die ODD auch Funktionsumfänge sowie weitere Umgebungsbedingungen wie Wetter, Tageszeit etc. fest.

## Online, Offline und Produktivsystem

Unter dem Begriff Online wird in dieser Arbeit die Ausführung von Algorithmen im Fahrzeug in Echtzeit verstanden. Demgegenüber steht die offline Ausführung von Algorithmen, die nicht in

Echtzeit und zudem außerhalb des Fahrzeuges erfolgt. Als Produktivsystem wird im Rahmen dieser Arbeit die zum gegenwärtigen Zeitpunkt noch nicht existierende freigegebene und zugelassene Automatisierung einer Straßenbahn bezeichnet, die online Daten auswertet und im regulären Fahrgastbetrieb ohne menschlichen Fahrer eingesetzt wird.

### Kritikalitätsmetriken

Um die Kritikalität eines bestimmten Szenarios oder Verkehrskonfliktes objektiv zu bewerten, werden üblicherweise sogenannte Kritikalitätsmetriken verwendet.<sup>30a</sup> Im Rahmen dieser Arbeit werden die Metriken *Time To Collision (TTC)* und *Time To Brake (TTB)* verwendet. Diese Metriken sind in der Literatur weit verbreitet und werden für verschiedene Anwendungen eingesetzt.

Die *TTC* drückt aus, wie viel Restzeit bis zum Zusammenstoß mit einem Objekt verbleibt.<sup>30b</sup> Zur Vorhersage der Ego- und Objektbewegungen wird zur einfachen Abschätzung meist ein konstantes Geschwindigkeitsmodell verwendet. Für die Relativgeschwindigkeit  $v_{\text{rel}} = v_{\mathcal{O}} - v_{\text{ego}}$  sowie den Abstand  $d_{\text{ego},\mathcal{O}}$  zwischen Ego-Fahrzeug und Objekt  $\mathcal{O}$  ergibt sich die *TTC* für Objekte vor dem Ego-Fahrzeug zu:

$$TTC = \begin{cases} \frac{d_{\text{ego},\mathcal{O}}}{|v_{\text{rel}}|}, & v_{\text{rel}} < 0 \\ \infty, & v_{\text{rel}} \geq 0 \end{cases} \quad (2-1)$$

Die *TTB* als Unterelement der allgemeinen *Time To Maneuver*<sup>30c</sup> drückt aus, wie viel Restzeit bleibt, bevor mit einer zugehörigen frei wählbaren Verzögerung gebremst werden muss, um einen Zusammenstoß zu vermeiden. Meist wird dafür eine maximale Verzögerung angenommen und die verbleibende Zeit bis zum erforderlichen Auslösen einer Gefahrenbremsung berechnet. Aufgrund dieser Bezugsbeschleunigung  $a_{\text{ref}}$  wird diese im weiteren Verlauf der Arbeit explizit als Index angegeben. Die *TTB* ergibt sich somit:

$$TTB_{a_{\text{ref}}} = \begin{cases} TTC - \frac{|v_{\text{rel}}|}{a_{\text{ref}}}, & v_{\text{rel}} < 0 \\ \infty, & v_{\text{rel}} \geq 0 \end{cases} \quad (2-2)$$

### Fahrschlauch

Als Fahrschlauch wird in dieser Arbeit der Raum vor der Straßenbahn entlang des Gleisverlaufes bezeichnet, der im Rahmen der Fahrt von der Straßenbahn beansprucht wird und für eine kollisionsfreie Vorbeifahrt frei von Hindernissen sein muss. Je nach Auslegung kann dies das Lichtraumprofil entlang des Gleises sein, wobei dieses neben der Fahrzeugkontur und der

30 Westhofen, L. et al.: Criticality Metrics for Automated Driving (2023), a: S. 1, b: S. 13, c: S. 14 & 22.

seitlichen Bewegung des Fahrzeugaufbaus in Kurven auch Sicherheitsabstände zur Infrastruktur berücksichtigt. Aus Gründen der Einfachheit und da die Zuordnung von Hindernissen in 2D erfolgt, wird in dieser Arbeit der Fahrschlauch als 2D Fläche entlang der Gleise mit konstantem Abstand  $d_{FS,krit}$  von der Gleismitte definiert, wie es nachfolgend in Abb. 2-3 dargestellt ist.

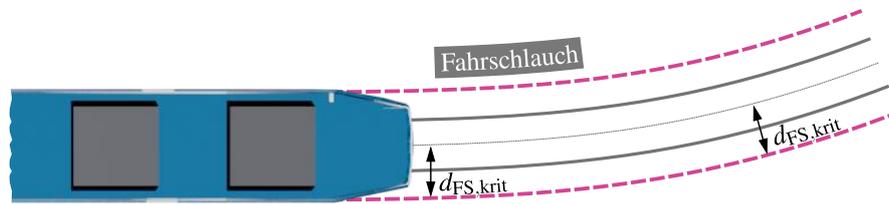


Abbildung 2-3: Definition des Fahrschlauches mit dem Abstand  $d_{FS,krit}$  zur Gleismitte.

Im Kraftfahrzeugbereich werden zusätzlich die Begriffe *Kurs* und *Trajektorie* verwendet, die im Rahmen dieser Arbeit bezüglich der Übertragbarkeit von Methoden genutzt werden. Der Kurs beschreibt den geplanten Fahrweg, was bei der Straßenbahn aufgrund der Spurbindung dem Gleisverlauf entspricht. Die Trajektorie verknüpft diesen Kurs zusätzlich mit der zeitlichen Komponente der geplanten Geschwindigkeit entlang des Fahrweges.

### Detektion und detektierte Objekte

Unter Detektion werden im Rahmen dieser Arbeit nach ISO 23150 eine technologiespezifische (Kamera, Lidar, Radar etc.) Einheit auf Grundlage einer einzelnen Messung eines Sensors verstanden.<sup>31</sup> Insbesondere sind diese noch keine Objekte, sondern bspw. für den Radar gemessene Datenpunkte zu Abstand, Geschwindigkeit, Azimuth und je nach Sensormodell auch Elevation.

Detektierte Objekte hingegen resultieren durch technologie- und sensorspezifische Auswertemethoden aus den Detektionen. Dabei werden üblicherweise mehrere Detektionen zu einem Objekt zusammengefasst, wobei je nach Auswertung auch Modelle und weiteres Vorwissen einfließen können. Im Rahmen dieser Arbeit werden detektierte Objekte mit  $\mathcal{O}_{det}$  abgekürzt.

### Phantomobjekt

Als Phantomobjekt wird im nachfolgenden ein detektiertes Objekt bezeichnet, das nicht real existiert, jedoch von einem Sensor bzw. einer nachfolgenden Auswertemethode als solches erkannt wird. Dies kann z. B. durch eine Fehlinterpretation oder durch eine Fehlfunktion des Sensors entstehen. Im Rahmen dieser Arbeit wird der Begriff Phantomobjekt ausschließlich für Objekte verwendet, die nicht real existieren und nicht durch andere Objekte verdeckt werden. Eine solche Verdeckung durch andere Objekte wird im weiteren Verlauf dieser Arbeit daher explizit als *Verdeckung* bezeichnet.

<sup>31</sup> ISO 23150: Datenkommunikation Sensoren und Datenfusionseinheit (2023).

## Regeln des gesunden Menschenverstandes

Der gesunde Menschenverstand, im englischsprachigen auch *Common Sense* bezeichnet, ist das durchschnittliche bzw. allgemeingültige Verständnis zu einem Sachverhalt. Insbesondere für den Straßenverkehr ergeben sich Regeln des gesunden Menschenverstandes, welche nicht explizit formuliert in einem Gesetz festgehalten sind, es jedoch zu beachten gilt.

## 2.2 Stand der Technik

Im folgenden Unterkapitel wird der Stand der Technik für verschiedene Themen zusammengefasst, um die notwendige Grundlage für das weitere Verständnis dieser Arbeit zu schaffen. Da *Silent Testing* eine zentrale Rolle dieses Forschungsansatzes ist, wird der zugehörige Stand der Technik im Rahmen der Methodenentwicklung in Kapitel 3 erläutert.

### 2.2.1 Umfeldsensorik

Sowohl im Bereich der Kraftfahrzeuge wie auch für schienengebundene Systeme werden je nach System und Zweck verschiedene Sensortechnologien zur Erfassung des Fahrzeugumfeldes eingesetzt. Üblicherweise kommen die Technologien Kamera, Radar, Lidar und Ultraschall zum Einsatz. Im Folgenden werden diese Technologien kurz erläutert und die Vor- und Nachteile aufgezeigt.

Auf Erläuterungen zu Ultraschallsensoren wird jedoch verzichtet, da diese im Rahmen dieser Forschung nicht genutzt wurden. Grundsätzlich könnte Ultraschall als Ergänzung zu Lidar genutzt werden, um den unmittelbaren Frontbereich der Straßenbahn — z. B. beim Anfahren an Haltestellen — auf Hindernisfreiheit zu prüfen. Der Verzicht auf Ultraschall liegt darin begründet, dass es sich hierbei um die erstmalige Anwendung des im nachfolgenden Kapitel aufgezeigten Forschungsansatzes handelt und die Komplexität zunächst reduziert werden soll.

#### Kamera

Kameras basieren auf dem passiven Empfang von Umgebungslicht, um ein digitales Bild der erfassten Umgebung zu erzeugen. Als bildgebende Verfahren liefern sie eine hohe Informationsdichte und ihr wesentlicher Vorteil, neben den vergleichsweise geringen Kosten, liegt in der Fähigkeit Farben und Texturen zu erfassen.<sup>32a</sup> Im Kontext des assistierten und automatisierten Fahrens, insbesondere von Kraftfahrzeugen, werden Kameras auf verschiedene Arten und Weisen wie Verkehrszeichenerkennung, Fahrstreifenenerkennung, Objekterkennung etc. mit unterschiedlichen Auswertemethoden eingesetzt.<sup>33a</sup>

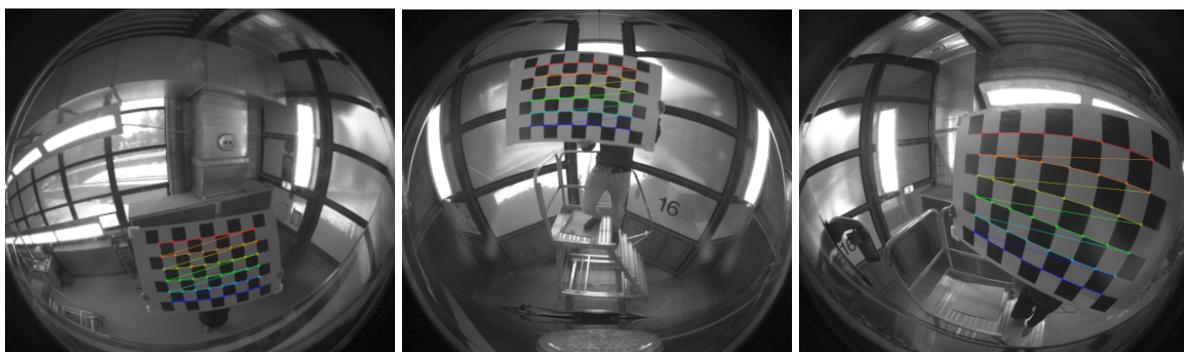
32 Campbell, S. et al.: *Sensor Technology in Autonomous Vehicles* (2018), a: S. 2, b: S. 1.

33 Bengler, K. et al.: *FAS und Automatisiertes Fahren* (2021), a: S. 351, b: S. 1021–1023, c: S. 1027.

Aufgrund ihrer üblichen Abbildung in ein zweidimensionales Bild sind Entfernungsdaten zu einem Objekt nur erschwert durch Stereotriangulation, maschinelle Schätzverfahren sowie als besondere Unterarten der Kameras mittels strukturiertem Licht oder *Time of Flight* zu ermitteln. Als wesentlicher Nachteil von Kameras gilt die Empfindlichkeit und Abhängigkeit vom umgebenden Licht, was sich besonders bei Gegenlicht, Szenerien mit hoher Dynamik, Nacht oder schlechten Wetterbedingungen negativ auf die Erkennung auswirkt.<sup>32a, 34</sup>

Kameras weisen üblicherweise eine sogenannte Verzeichnung auf, die als Abbildungsfehler aufgrund der verwendeten Linsen und Darstellung in einem ebenen Bild entstehen. Insbesondere Fischaugenobjektive, wie sie in dieser Arbeit als Nahsichtkameras eingesetzt werden, weisen eine starke sogenannte tonnenförmige Verzeichnung auf. Für die Verknüpfung mit bekannten 3D-Punkten, wie bspw. die Projektion eines mit Lidar bestimmten Objektes in das Kamerabild, ist eine Korrektur der Verzeichnung in Form einer Kalibration notwendig.<sup>35</sup>

Nachfolgende Abb. 2-4 zeigt die Verzeichnung der drei in dieser Arbeit eingesetzten Nahsichtkameras, deren Nutzung und Positionierung im Fahrzeug im weiteren Verlauf in Kapitel 3.3.4 erläutert wird.



(a) Linke Nahsichtkamera

(b) Mittlere Nahsichtkamera

(c) Rechte Nahsichtkamera

Abbildung 2-4: Verzeichnung der drei in der Straßenbahn eingesetzten Nahsichtkameras aufgrund von Fischaugenobjektiven. Es handelt sich um Farbkameras, die Bilder sind nur als Teil des Kalibrationsprozesses mittels Schwarz-Weißem Kalibrationsmuster in Graustufen dargestellt. Sowohl an dem Kalibrationsmuster, wie den vertikalen und horizontalen Streben von Türen oder Fenstern, ist die tonnenförmige Verzeichnung besonders deutlich zu erkennen.

## Radar

*Radio Detection and Ranging* (Radar) stammt ursprünglich aus der militärischen Anwendung und ist heute als häufig genutzter Sensor für den Abstandsregeltempomat (ACC) sowie gesetzlich vorgeschriebene Notbremssysteme im Kraftfahrzeugbereich weit verbreitet.<sup>33b</sup> Radarsensoren senden aktiv elektromagnetische Wellen aus. Dies erfolgt mit mehreren Sendempfangsantennen sowie einer Strahlbündelung und nicht als kugelförmige Welle. In Abhängigkeit des Reflexionsvermögens, welches von Material und Form des Objektes abhängt, lösen sie eine

34 Marti, E. et al.: Review of Sensor Technologies for Perception (2019), S. 95.

35 Weng, J. et al.: Camera calibration with distortion models and accuracy evaluation (1992).

Reflexion aus, die vom Sensor empfangen wird. Aus der Laufzeit der Strahlen und der bekannten Ausbreitungsgeschwindigkeit der elektromagnetischen Wellen kann die Entfernung zu einem Objekt bestimmt werden.

Durch die Verwendung mehrerer Antennen kann neben der Distanz zusätzlich die Richtung des Objektes zum Sensor bestimmt werden.<sup>32b, 33b</sup> In kommerzieller Anwendung erfolgt dies üblicherweise nur in Azimuth, weshalb bisherige Radar Generationen nicht über eine Elevationsmessung verfügen. Darüber hinaus ist die Auflösung in Azimuth etwa eine Größenordnung geringer als für Lidar oder Kamera, weshalb die Detektionen von Radar vergleichsweise weniger zahlreich sind<sup>36</sup> und die Technologie im Vergleich mit Lidar meist eine geringere Auflösung aufweist. Im Gegensatz zu Kamera und konventionellem Lidar ermöglicht Radar darüber hinaus die Geschwindigkeit eines Objektes durch die Dopplerverschiebung der reflektierten Wellen in radialer Richtung, als direkte Messgröße zu bestimmen. Radar ist unabhängig von den vorherrschenden Lichtverhältnissen. Witterungsbedingt schränkt Starkregen aufgrund erhöhter Dämpfung die Reichweite ein und kann sogar Fehldetektionen verursachen. Im direkten Vergleich mit Kamera und Lidar ist Radar jedoch weniger anfällig für Witterungseinflüsse.<sup>32b, 33b</sup>

## Lidar

In Anlehnung an Radar steht der Begriff Lidar für *Light Detection and Ranging* und ist ein aktives Sensorprinzip, welches auf nicht sichtbarem Laserlicht beruht. Bisher beruhen Lidarsensoren mehrheitlich auf dem *Time of Flight* Prinzip, wobei ein kurzer, gerichteter Lichtimpuls ausgesendet und die Laufzeit bis zur Reflexion von einem Objekt gemessen wird. Aus der Laufzeit und der bekannten Lichtgeschwindigkeit kann die Entfernung zu einem Objekt bestimmt werden. Konventionelle Lidare erreichen eine zweidimensionale Messung in der Ebene, indem Sende- und Empfangsdiodenpaar oder ein Spiegel mechanisch schnell rotiert werden, dabei mehrfach Messen und die für jede Messung zugehörige Winkelposition während des Messvorgangs ebenfalls bestimmt wird.<sup>32b</sup> Es ist jedoch ein Wandel zu sogenannten *Solid State* Lidaren zu beobachten, bei denen anstelle größerer Bauteile nur noch mit MEMS kleine Spiegel bewegt oder die Szenerie mit gepulstem Laser Licht bestrahlt und Reflexionen mit einem Empfangs-Array (Flash-/CMOS-Lidar) erfasst werden.<sup>37</sup> Folglich lassen sich mit Lidarsensoren in Azimuth je nach Umsetzung Auflösungen von bis zu  $0,1^\circ$  erreichen.<sup>33c</sup>

Die Messung in Elevation und somit Erzeugung einer 3D-Punktwolke erfolgt durch mehrere Ebenen nach dem oben beschriebenen Prinzip. Die Ebenen sind dabei um den Horizont geneigt, um ein entsprechendes vertikales *Field of View* (FoV) zu ermöglichen. Aufgrund der endlichen Anzahl von Ebenen ergeben sich verglichen mit der horizontalen Auflösung große Detektionslücken in vertikaler Richtung. Der unter anderem eingesetzte Velodyne VLP-32C hat bspw. 32 solcher Ebenen, wobei die vertikale Verteilung nicht äquidistant erfolgt, weshalb die vertikale

<sup>36</sup> Zheng, L. et al.: TJ4DRadSet (2022), S. 495.

<sup>37</sup> Li, N. et al.: Review on Solid-State LiDAR (2022).

Auflösung je nach betrachteten Ebenen zwischen  $0,33^\circ$ – $9,36^\circ$  liegt. Zur Verdeutlichung ist dazu nachfolgend in Abb. 2-5 die Punktwolke — also die Detektionen — dieses Sensors dargestellt. Durch die Montage auf dem Dach sind im Bereich unmittelbar vor der Bahn (FoV-Rand) die vergleichsweise wenigen Detektionen des schwarzen Fahrzeugs rechts im Vergleich zu dem etwas weiter entfernten roten Fahrzeug links zu erkennen.

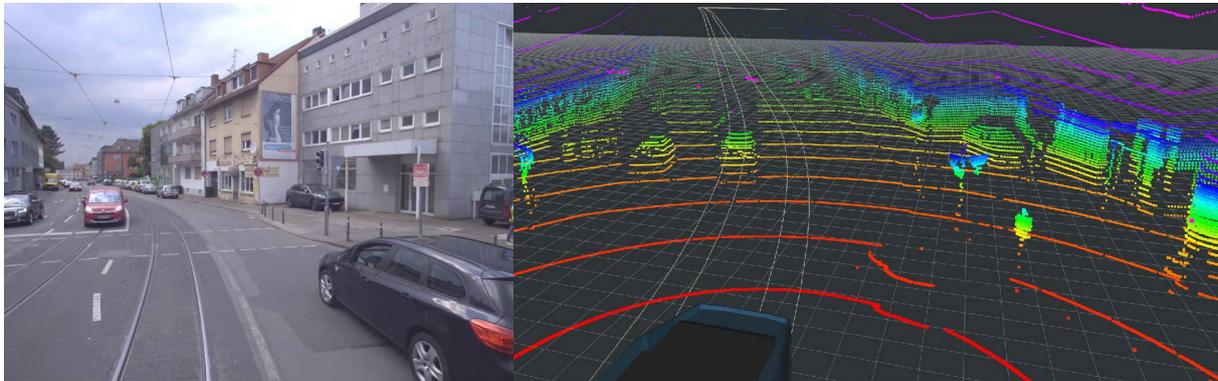


Abbildung 2-5: Aufgrund der nicht äquidistanten Verteilung der Ebenen weist der Velodyne VLP-32C im Randbereich des FoV eine geringere Punktdichte auf. Der schwarze Pkw wird nur von zwei Ebenen, während der rote Pkw von 11 Ebenen erfasst wird. Die Einfärbung der Punkte entspricht je einer der 32 Ebenen des Sensors.

Aufgrund der Detektionslücken des Velodyne VLP-32C durch die Dachmontage wird für den Nahbereich zusätzlich, wie nachfolgend in Kapitel 3.3.4 erläutert, ein weiterer Lidar eingesetzt. Dessen Detektionen sind in der obigen Abbildung nicht dargestellt. Im Gegensatz zu Radar erfolgt bei bisherigen Lidarsensoren aufgrund eines fehlenden wirtschaftlichen technischen Konzeptes keine Messung der Geschwindigkeit von Detektionen mittels Dopplereffekt.<sup>33c</sup> Jedoch befinden sich bereits neuartige Lidarsensoren im Prototypenstadium, die ähnlich wie Radar durch moduliertes Licht (FMCW) eine Geschwindigkeitsmessung in radialer Richtung ermöglichen.<sup>38</sup>

## 2.2.2 Automatisierung von Metros und Vollbahnen

Zur Einordnung der in dieser Arbeit beschriebenen Automatisierung von Straßenbahnen wird im folgenden Abschnitt die Automatisierung von Metros und Vollbahnen zusammengefasst.

Wie bereits zur Definition des Begriffs „Straßenbahn“ erwähnt, existiert basierend auf den Vorarbeiten des Internationalen Verbandes für öffentliches Verkehrswesen eine Einteilung der Automatisierungsstufen in GoA 0–4 für Metros.<sup>39, 40</sup> Die Stufen sowie die zugrundeliegenden Kategorien sind vereinfacht in Tabelle 2-1 zusammengefasst.

38 Sayyah, K. et al.: Fully Integrated FMCW LiDAR Engine (2022).

39 Die Norm bezieht sich auf den „städtischen schienengebundenen Personennahverkehr“

40 DIN EN 62290: Betriebsleit- und Zugsicherungssysteme (2015).

Tabelle 2-1: Vereinfachte Zusammenfassung der GoA Stufen 0–4 nach DIN EN 62290<sup>40</sup> und Schnieder<sup>41a</sup>.

<b>Funktion</b>	<b>GoA 0</b>	<b>GoA 1</b>	<b>GoA 2</b>	<b>GoA 3</b>	<b>GoA 4</b>
<b>Sichere Zugbewegung</b>					
Einstellen des Fahrweges, Weichen, Abstände etc.	Mensch	System	System	System	System
<b>Fahren</b>					
Beschleunigen und Bremsen nach Fahrprofil	Mensch	Mensch	System	System	System
<b>Hindernisfreiheit</b>					
Kollisionen mit Objekten und Personen verhindern	Mensch	Mensch	Mensch	System	System
<b>Fahrgastwechsel</b>					
Steuern der Türen, Überwachen der Bahnsteigkante, Sicherstellen d. Abfertigungsbedingungen	Mensch	Mensch	Mensch	Mensch / System	System
<b>Betrieb</b>					
Ein- u. Aussetzen, Überwachen des Fahrzeuges	Mensch	Mensch	Mensch	Mensch	System
<b>Störungen</b>					
Diagnose, Erkennen (inkl. Feuer) entsprechend Handeln	Mensch	Mensch	Mensch	Mensch	Mensch / System

Dabei existieren im Bereich der Metros, basierend auf der Zugbeeinflussung und Zugsicherung *Communication Based Train Control* (CBTC), bereits seit mehreren Jahren vollautomatische GoA 4 Systeme, die einen Betrieb ohne Betriebspersonal in der Bahn ermöglichen.<sup>42, 43</sup> Laut Internationaler Verband für öffentliches Verkehrswesen (UITP) sind weltweit im Jahr 2020 etwa 1.358 km Streckennetz von Metros vollständig automatisiert. Hierbei handelt es sich um zentrale Sicherheitsarchitekturen. Alle Verkehrsteilnehmer (andere Züge, Sonderfahrzeuge der Wartung etc.) sowie Zustände der Infrastruktur dieser Systeme sind zentral erfassbar, sodass auch Fahrfreigaben für die **sichere Zugbewegung** zentral erteilt und entzogen werden. Insbesondere das für die Straßenbahn relevante Feststellen der **Hindernisfreiheit** erfolgt für Metros durch eine Kombination mehrerer Maßnahmen, deren Grundgedanke jedoch die Eigen-Reservierung des Verkehrsraums für die Metro ist. Dazu zählen bauliche Maßnahmen wie Bahnsteigtüren, Einfrie-

41 Schnieder, L.: Communications-Based Train Control (CBTC) (2021), a: S. 28–29 b: 63 ff.

42 Schnieder, L.: Automatisierung im schienengebundenen Nahverkehr (2019).

43 Beismann, H.; Schmidt, V.: Schienenfahrzeuge für den fahrerlosen U-Bahnbetrieb (2005).

dungen, Tunnel, Umfeldsensoren an Tunnelleingängen oder im Gleisbett von Bahnsteigen etc.<sup>40b</sup> Komplexe Szenarien und mit anderen Verkehrsteilnehmern geteilte Verkehrsräume werden dabei nicht betrachtet. Es existieren jedoch Forschungsprojekte, die mit komplexeren Umfeldsensoren (bspw. Kamera oder Lidar) versuchen die Hindernisfreiheit auch vom Fahrzeug aus zu prüfen.<sup>44</sup>

Im Gegensatz zu Metros ist eine fahrerlose automatisierte Vollbahn noch nicht im Produktiveinsatz. Die Automatisierung der Vollbahn ist jedoch Gegenstand von Forschung und Entwicklung. Insbesondere für die **sichere Zugbewegung** wird in Europa an ATO via *European Train Control System* (ETCS) als zentrale Architektur der Zugsicherung gearbeitet. Neben der reinen Zugsicherung existieren verschiedene Bestrebungen zur sensorischen Umfelderkennung, um die **Hindernisfreiheit** auch bei Vollbahnen maschinell zu gewährleisten.<sup>45, 46, 47, 48</sup> Auch das „*Deutsche Zentrum für Schienenverkehrsforschung beim Eisenbahn-Bundesamt (DZSF)*“ beschreibt die Umfeldsensorik als technische Voraussetzung für automatisiertes Fahren der Vollbahn und schlägt neben Wahrnehmungsbereichen der Sensorik auch erste Beispielszenarien zu Anwendungsfällen vor.<sup>49</sup> Dabei werden sowohl in den Bestrebungen des DZSF wie auch den anderen Forschungs- und Entwicklungsbestrebungen die aus dem Kraftfahrzeugbereich bekannten und oben beschriebenen Sensoren wie Kamera, Radar und Lidar mit unterschiedlichen Auswertemethoden eingesetzt oder vorgeschlagen. Ähnlich wie bei Kraftfahrzeugen hat sich dabei bisher keine einheitliche Lösung oder eindeutig überlegenes Konzept durchgesetzt.

### 2.2.3 Assistenz und Automatisierung der Straßenbahn

In diesem Unterabschnitt wird auf die Entwicklung und Forschung zu Assistenzsystemen und Automatisierung der Straßenbahn eingegangen. Es werden nur Assistenzsysteme zu unmittelbaren Fahraufgaben wie Notbremsysteme, Kollisionswarnungen etc. betrachtet. Assistenzsysteme zur Unterstützung und Optimierung des Fahrgastwechsels, Fahrempfehlungen zu besonders energieeffizientem Fahren etc. werden aufgrund der Fokussierung auf die wesentlichen Fahraufgaben nicht betrachtet.

#### Assistenzsysteme der Straßenbahn

Für die Straßenbahn existieren Kollisionswarnsysteme von verschiedenen Anbietern, die teilweise auch als aktives System eigenständig eine Bremsung auslösen. Aufgrund des kommerziellen Hintergrundes dieser Systeme sind keine Details zu genauen Auswertemethoden öffentlich kommuniziert.

44 Zhang, Q. et al.: Obstacle Detection Method for the Train (2023).

45 Tilly, R. et al.: Multisensordatensatz (2023).

46 Tagiew, R. et al.: Onboard Sensor Systems for Automatic Train Operation (2022).

47 Weichselbaum, J. et al.: Accurate 3D-vision-based obstacle detection for an autonomous train (2013).

48 Ristić-Durrant, D. et al.: Vision-Based On-Board Obstacle Detection (2021).

49 Leinhos, D. et al.: Sensorik als Voraussetzung für ATO (2022).

- **Bosch Engineering:** Das *Tram-Forward-Collision-Warning* (TFCW) System von Bosch Engineering setzt auf eine Kombination aus Monokamera und Radar aus dem Automobilbereich.<sup>50</sup> Die Kamera erfasst den Gleisverlauf, während der Radar Objekte detektiert. Das System kann je nach Ausführung nur eine Warnung ausgeben oder eine automatische Bremsung auslösen.<sup>51, 52</sup>
- **Bombardier:** Mit den Systemen „ODAS/COMPAS“ bietet Bombardier ein System an, welches basierend auf Kameras Hindernisse der Umgebung detektiert. Der dafür genutzte Stereoalgorithmus setzt für Nah- und Fernbereich auf zwei unterschiedliche Basisbreiten, was durch die Nutzung von drei Kameras ermöglicht wird. Diese Objektdetektion mittels Stereotriangulation basiert auf einer Entwicklung des Austrian Institute of Technology (AIT).<sup>53</sup> Als Ergänzung zur kamerabasierten Detektion des Gleisverlaufes existieren Varianten, bei denen der Gleisverlauf aus einer Karte abgerufen wird.<sup>54</sup>
- **Continental Engineering Services:** Das System zur Kollisionswarnung von Continental Engineering Services besteht aus einem Radar aus dem Automobilbereich sowie einer kartenbasierten Bestimmung des Gleisverlaufes.<sup>55</sup> Zukünftig soll auch die Intention zum Abbiegen anderer Verkehrsteilnehmer berücksichtigt werden.<sup>56</sup>
- **Škoda:** Die Detektion von Hindernissen erfolgt mittels Lidar und Kamera,<sup>57</sup> jedoch sind keine weiteren Details zu dem 2022 angekündigten System verfügbar.

Darüber hinaus existieren im Kontext der Straßenbahn vereinzelte erste Forschungsansätze von Universitäten zur Objektdetektion, die mittels Kamera und Machine Learning Methoden versuchen, Objekte des Umfelds zu erfassen.<sup>58, 59</sup> Neben den oben genannten Firmen existieren darüber hinaus Start-ups, welche für Notbremssysteme auf die Kombinationen mehrerer Sensoren wie Kamera, Radar und Lidar setzten.<sup>60, 61</sup>

---

50 BOSCH: Ten years of developing tram assistance systems (2022).

51 BOSCH: Datenblatt TFCW (2021).

52 Anz, R.: Prüfverfahren Kollisionswarnsysteme für Straßenbahnen (2020).

53 Gerrard, J.: Bombardier's driver assistance system (2017).

54 Fel, L. et al.: ODAS – An anti-collision assistance system (16).

55 Continental: Future of Urban Rail (2018).

56 Clemenz, M.: Abbieger auf Irrwegen (2023).

57 intellicar: Škoda präsentiert Antikollisionssystem (2022).

58 Guerrieri, M.; Parla, G.: Smart Tramway Systems for Smart Cities (2022).

59 Guzhva, N. S. et al.: 3D Object Detection DNN (2022).

60 OTIV: ADAS OTIV.TWO (2023).

61 Cognitive Pilot: Tram Pilot (2019).

## Automatisierung der Straßenbahn

Das Forschungs- und Entwicklungsgebiet zur Automatisierung von Straßenbahnen ist im Vergleich zu Kraftfahrzeugen und Metros neu, weshalb bisher nur vereinzelt Hersteller von Straßenbahnen eine Automatisierung ohne nähere Spezifikationen oder Details in Aussicht gestellt haben.<sup>62, 63, 64</sup> In der wissenschaftlichen Literatur gibt es bisher nur vom Straßenbahnhersteller Siemens zwei Veröffentlichungen zu technischen und technologischen Hintergründen der Automatisierung von Straßenbahnen.<sup>65, 66</sup> Dabei hat Siemens 2018 einen Versuchsträger vorgestellt, der im Rahmen einer Demonstration prototypisch eine 6 km lange Strecke auf unabhängigen und besonderen Bahnkörpern im Potsdamer Streckennetz mit Sicherheitsfahrer automatisiert zurückgelegt hat. Der Versuchsträger, der in keiner Form im Linienbetrieb eingesetzt wird, sowie die Visualisierung der Demonstration sind nachfolgend in Abb. 2-6 dargestellt.

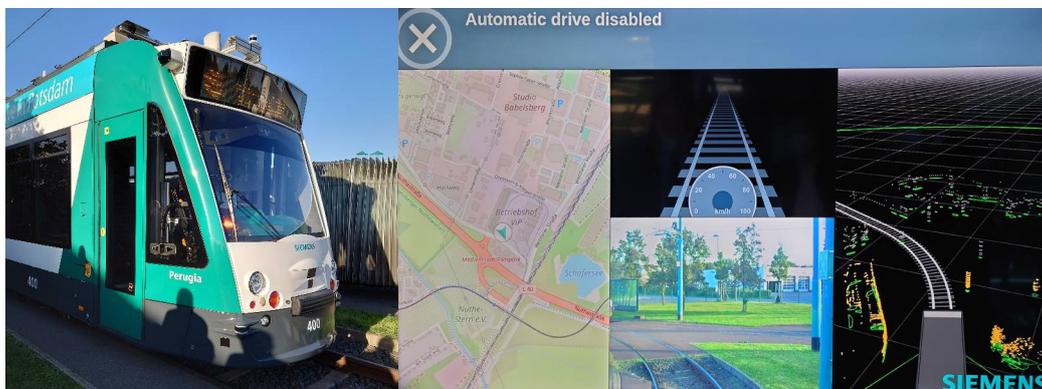


Abbildung 2-6: Versuchsträger Siemens.<sup>67</sup>

Mittlerweile verfügt der Versuchsträger über andere Sensoren, welche jedoch nicht öffentlich kommuniziert sind. Zur Vorstellung 2018 war er mit zwei 16-Ebenen Lidarsensoren, einem 4-Ebenen Lidar sowie drei Radaren aus dem Automobilbereich und neun Kameras zur Umfelderkennung ausgerüstet. Die Sensoren detektierten einzeln Objekte, die in einer nicht weiter spezifizierten Fusion zusammengeführt wurden. Zur Lokalisierung setzte der Versuchsträger auf eine Fusion von *Global Navigation Satellite System* (GNSS) mit Inertialsensoren sowie eine Karte ohne weitere Details zu den verwendeten Sensoren oder Auswertemethoden.<sup>66</sup> Die Zustände von LSA wurden mittels Kameras und einem *Single Stage Detector* als Machine Learning Ansatz erfasst. Als Herausforderungen beschreibt Siemens einerseits die Nutzung von Radar, da aufgrund der metallischen Infrastruktur der Straßenbahnen die Sensordetektionen von weniger reflektierenden Menschen nicht von denen der Infrastruktur zu unterscheiden seien.

62 CAF: Connected and automated transport (2023).

63 Thales: AI for the autonomous trams (2019).

64 Siemens: Autonomous trams on the rail and in the depot (2023).

65 Hofmann, M.: Trams das Fahren lehren (2020).

66 Palmer, A. W. et al.: The Autonomous Siemens Tram (2020).

67 Fotos ursprünglich von Patrick Pintscher.

Andererseits wird Vegetation am Boden als Herausforderung der Objektdetektion beschrieben, da diese im genutzten Lidar-Clustering als falsch positive Hindernisse am Boden erfasst worden sind.<sup>66</sup> In dem Projekt „AStriD“ hat Siemens ihre Forschungs- und Entwicklungsbemühungen auf die Automatisierung im Depot als ersten kommerziellen *Use Case* fokussiert, der 2026 als Produkt angeboten werden soll.<sup>68</sup>

## 2.3 Forschungsfragen

Zur Einbettung dieser Arbeit im Kontext der Forschung werden im Folgenden Forschungsfragen formuliert. Dabei wird die Anwendung von *Silent Testing* vorgegriffen, welche in Kapitel 3 erläutert wird.

Basierend auf der übergeordneten Motivation und der Neuartigkeit der Automatisierung im Bereich Straßenbahn zielt die erste Forschungsfrage FF. 1 als Leitfrage dieser Arbeit auf die Identifikation der wesentlichen Probleme ab.

### FF. 1

Welche wesentlichen neuen Herausforderungen ergeben sich bei der Automatisierung von Straßenbahnen?

Durch den experimentellen und neuartigen Ansatz der nachfolgend vorgestellten *Silent Testing* Methode in der Domäne der Straßenbahn sowie der Motivation die zuvor aufgezeigte Frage mit *Silent Testing* zu beantworten, wird die zweite Forschungsfrage FF. 2 auf die Anwendbarkeit der Methode auf die Automatisierung von Straßenbahnen gerichtet.

### FF. 2

Können mit *Silent Testing* als Werkzeug der Funktionsentwicklung Herausforderungen des automatisierten Fahrens von Straßenbahnen identifiziert und neuartige Lösungsansätze plausibilisiert werden?

Da als Teil von *Silent Testing* eine Metrik für den Vergleich von Mensch und Maschine erforderlich ist, ist in der dritten Forschungsfrage die Gestaltung einer solchen Metrik für die Anwendung auf Straßenbahnen gefordert.

### FF. 3

Wie kann zur Anwendung von *Silent Testing* ein Vergleich von menschlichem und maschinellem Verhalten bei der Automatisierung von Straßenbahnen gestaltet werden?

---

<sup>68</sup> Bahn Manager: Autonome Tram findet ihren Weg im Depot (2021).

Bei *Silent Testing* handelt es sich um einen experimentellen Ansatz, der ein sogenanntes *Object under Test* (OuT) in Form eines Automatisierungssystems erfordert. Da die Automatisierung von Straßenbahnen jedoch nahezu unerforscht ist, stellt sich bezüglich Umsetzung die Frage, welche Funktionalitäten eine Automatisierung von Straßenbahnen aufweisen muss. Daher wird mit FF. 4 die Erarbeitung von Anforderungen sowie einer generischen Referenzarchitektur zur Automatisierung von Straßenbahnen motiviert.

### **FF. 4**

Welchen Funktionsumfang bezüglich der Fahraufgabe muss eine Automatisierung von Straßenbahnen aufweisen?

## 3 Silent Testing als Methode

Wie einleitend in Kapitel 1 erläutert, existiert ein Bedarf zur realitätsnahen Überprüfung von technischen Lösungen zum automatisierten Fahren, um so bereits früh im Entwicklungsprozess neue Anforderungen zu identifizieren und entwickelte Lösungsansätze zu plausibilisieren. Im Vergleich zu Realtests mit aktivem Automatisierungssystem erhöht die nachfolgend vorgestellte Methode mittels *Silent Testing* das Risiko für Insassen und Umgebung nicht. Dies ist darin begründet, dass bei *Silent Testing* eine passive Evaluation erfolgt, während das Fahrzeug weiterhin von einem menschlichen Fahrer geführt wird. Der Fokus der Methode liegt im Rahmen dieser Arbeit nicht auf der Validierung — also dem Sicherheitsnachweis — von Fahrfunktionen. Es wird antizipiert, dass sich bei der komplexen Umgebung im Stadtverkehr sowie der für Straßenbahnen annähernd unerforschten Automatisierung bereits neue Anforderungen und erhebliche Herausforderungen zu Beginn des Entwicklungsprozesses, d. h. vor der Validierung ergeben.

### 3.1 Anforderungen an die Methode

Zur Beschreibung der Anforderungen an die Methode selbst wird von einem hypothetischen Entwicklungsprozess der Automatisierung von Straßenbahnen ausgegangen. Zur Umsetzung eines automatisierten Fahrauftrages sind die frühe Identifikation von Herausforderungen und Plausibilisierung von Lösungsansätzen zu ermöglichen, um diese in einem Entwicklungsprozess zielgerichtet von Beginn an adressieren zu können. Dabei wird keine Vollständigkeit der Herausforderungen erwartet, da keine Validierung im Rahmen eines Sicherheitsnachweises erfolgt, sondern erstmalig die größten Probleme bei der Automatisierung von Straßenbahnen aufgezeigt werden. Darüber hinaus gilt entsprechend der im Kraftfahrzeugbereich angewendeten SOTIF, dass aufgrund der Offenheit der Welt unbekannte Szenarien auch im späteren Betrieb nicht ausgeschlossen werden können. Zusammenfassend sind die nachfolgenden Anforderungen an die Methode formuliert:

- **Reduzierung der un-/bekannten Unbekannten:** Innerhalb der realen Welt werden neue Herausforderungen erwartet. Diese „bekannten Unbekannten“ (auch *known unknowns* genannt) sollen sowohl in Abhängigkeit von der verwendeten Technologie und den dabei eingesetzten Algorithmen wie auch unabhängig davon (allgemeingültig für die Automatisierungsaufgabe, also unabhängig der technischen Lösung) identifiziert werden. Darüber hinaus sollen auch „unbekannte Unbekannte“ (auch *unknown unknowns* genannt) identifiziert werden. Diese werden nicht erwartet und können daher nicht gezielt gesucht werden.

Sie können jedoch grundsätzlich durch die Methode aufgedeckt werden, wenn sie in den auszuwertenden Realdaten enthalten sind.

- **Zuordnung zu Verarbeitungsschritten:** Identifizierte Herausforderungen sollen einzelnen Verarbeitungsschritten der Automatisierung, also einzelnen Funktionen, zugeordnet werden. Dies ermöglicht die zielgerichtete Weiterentwicklung der einzelnen Komponenten der Automatisierung.
- **Praktische Plausibilisierung von Lösungsansätzen:** Die Methode soll eine Plausibilisierung von straßenbahnspezifischen bzw. grundsätzlich neuen Lösungsansätzen ermöglichen. Insbesondere werden darunter neue Lösungsideen verstanden, die sich erst aus der Domäne Straßenbahn mit ihrem beschränkten Einsatzgebiet, der Schienengebundenheit, der spezifischen Infrastruktur und dem Betrieb im Rahmen einer Verkehrsgesellschaft ergeben.<sup>69</sup>
- **Automatisierte oder teilautomatisierte Auswertung:** Um möglichst viele Herausforderungen zu identifizieren bzw. Lösungsansätze überprüfen zu können, muss eine möglichst große Datenbasis ausgewertet werden. Daher soll die Auswertung automatisiert oder teilautomatisiert erfolgen. Dabei sind zusätzliche händische Einzelfallanalysen nicht ausgeschlossen. Deren jeweiligen Realdaten zur Detailanalyse sollen jedoch aus einer möglichen Vielzahl an Realfahrten ebenfalls automatisiert identifiziert werden.

## 3.2 Entwicklungswerkzeug Silent Testing

Der Sicherheitsnachweis eines Systems oder einer Funktion — im Folgenden mit der üblichen englischsprachigen Bezeichnung OuT zusammengefasst — impliziert den Umgang mit Herausforderungen durch Überprüfung von Lösungsansätzen. Bisher gibt es keine allgemeingültige Gesamtmethode zur Validierung von automatisiertem Fahren ohne menschliche Überwachung im Kraftfahrzeug- oder Bahnbereich. Wird jedoch auf den abschließenden Sicherheitsnachweis verzichtet, so können Teile der derzeit in Entwicklung und Anwendung befindlichen Methoden des Sicherheitsnachweises in abgewandelter Form zur Identifikation von Herausforderungen und Plausibilisierung von Lösungsansätzen eingesetzt werden.

Um ein OuT zu überprüfen, existieren grundsätzlich verschiedene Möglichkeiten. Realtests, also der Einsatz des OuT in betriebsähnlichen Tests unter Einsatz der entwickelten Algorithmen, bieten die größte Validität, da die Bedingungen und Wechselwirkungen der späteren Anwendung entsprechen. Für den statistischen Sicherheitsnachweis des automatisierten Fahrens von Pkw haben Winner und Wachenfeld je nach Einsatzort und Konfidenz die zu absolvierenden

---

<sup>69</sup> Elemente wie die Schienengebundenheit gelten auch für Vollbahnen und Metros.

Testfahrten auf mehrere Milliarden Testkilometer bestimmt.<sup>70, 71</sup> Da dies jedoch aufgrund des Aufwands nicht vertretbar ist, wird an weiteren Methoden sowie deren Kombination zum Sicherheitsnachweis geforscht. Darunter fällt der simulative Ansatz, bei dem ein Teil dieser Testfahrten bzw. einzelne Komponenten oder Verarbeitungsschritte virtuell abgebildet und somit validiert werden sollen.<sup>72, 73</sup> Simulationen können schneller als Echtzeit ablaufen, Randbedingungen sind anpassbar, der gleiche Test kann mit unterschiedlichen OuT wiederholt werden und das Risiko wird von der realen Welt in eine virtuelle verlagert. Allerdings ist die Simulation nur so gut wie die zugrundeliegenden Modelle sowie die simulierten Szenarien und damit Abbildungen der realen Welt: So kann bspw. auch ein hinreichend genaues Sensormodell eines Sensors ungenügende Ergebnisse liefern, wenn die Umgebungsmodellierung nicht ausreichend ist. Insbesondere können sich auch Verkehrsteilnehmer in der Simulation anders verhalten als in der Realität, da die Komplexität der realen Welt und insbesondere die Vielfalt möglicher menschlicher Fehlverhalten nicht vollständig abgebildet werden kann. Daher ist die Simulation nur ein Teil der Methoden zum Sicherheitsnachweis.

Eine Brücke zwischen diesen beiden Herangehensweisen bildet das sogenannte *Silent Testing* Konzept. Hierbei wird ein Fahrzeug von einem Menschen in seinem alltäglichen Gebrauch eingesetzt. Zusätzlich ist das Fahrzeug mit Sensorik des automatisierten Fahrens ausgestattet. Die Sensordaten werden einem OuT, also einem entwickelten Automatisierungssystem zugeführt und so eine Fahranweisung maschinell bestimmt. Diese wird jedoch noch nicht umgesetzt, das OuT hat also keinen Einfluss auf die tatsächliche Bewegung des Fahrzeuges, da dieses weiterhin unabhängig vom OuT vom Menschen gefahren wird. Die Automatisierung befindet sich somit in einem Schattenmodus. Die maschinell bestimmte Fahranweisung lässt sich durch eine eigenständige Prüfung der Kritikalität der Fahranweisung evaluieren oder durch einen Vergleich mit dem tatsächlich durchgeführten Manöver des menschlichen Fahrers. In letzterem Fall gilt der menschliche Fahrer als Referenz. Als Nachteil dieses Ansatzes ist zu bewerten, dass das OuT keine Wechselwirkung mit der Umgebung eingeht. Demnach können keine Reaktionen anderer Verkehrsteilnehmer auf das OuT berücksichtigt werden. Darüber hinaus ist der Fahrzustand durch die menschliche Führung erzwungen. Die Untersuchung von Folgereaktion auf eine möglicherweise noch nicht falsche, aber vom Menschen unterschiedliche Fahranweisung ist somit nicht möglich.

### 3.2.1 Grundlage Silent Testing

Zur Adressierung der oben genannten Anforderungen ist ein rein simulativer Ansatz zur Untersuchung der Straßenbahnautomatisierung nicht ausreichend. Zwar existieren einige wenige

---

70 Winner, H. et al.: Handbuch Fahrerassistenzsysteme (2015), S. 1174–1177.

71 Bengler, K. et al.: FAS und Automatisiertes Fahren (2021), S. 457–458.

72 Zofka, M. R. et al.: Testing and validating high level components for automated driving (2016), S. 144.

73 Maurer, M. et al.: Autonomes Fahren (2015), S. 44–447, 461–462.

Simulationswerkzeuge für Straßen- bzw. Eisenbahnen<sup>74</sup>, die grundsätzlich für die Erforschung des automatisierten Fahrens verwendet werden können, jedoch lassen sich mit diesen aufgrund der oben genannten ungenügenden Abbildung der realen Welt nur wenige bekannte Unbekannte aufdecken. Hinzu kommt, dass wie in Kapitel 1 gezeigt, die Automatisierung von Straßenbahnen bisher wenig erforscht ist und somit die spezifische ungenügende Abbildung der realen Welt noch stärker ins Gewicht fällt. Dem gegenüber steht, dass Tests mit Realfahrten zwar grundsätzlich die oben genannten Anforderungen an die Methode erfüllen, jedoch aufgrund der hohen Kosten und der geringen Verfügbarkeit von Testfahrzeugen nur in geringer Anzahl durchgeführt werden können. Dabei ist zusätzlich zu bedenken, dass Straßenbahnen im Vergleich zu Kraftfahrzeugen einen deutlichen höheren Stückpreis und auch Wartungskosten aufweisen.

Für die Anwendung von *Silent Testing* kann hingegen ein bestehendes Fahrzeug verwendet und Sensorik sowie Recheneinheiten zur Aufnahme nachgerüstet werden. Durch die Nutzung eines Bestandsfahrzeuges, welches weiterhin im regulären Betrieb eingesetzt wird, ergeben sich folgende Vorteile:

- Die Kosten für die Beschaffung und die übliche Wartung des Fahrzeuges entfallen bzw. sind dem regulären Betrieb zugeschrieben.
- Die Kosten für explizite Testfahrten entfallen, da das Testen im regulären Betrieb erfolgt.
- Der Einsatz im Linienbetrieb ermöglicht eine große Menge an Daten, da Straßenbahnen üblicherweise mit mehreren Fahrern dauerhaft während der täglichen Betriebszeiten des örtlichen ÖPNV eingesetzt werden.
- Tests mit einer vollständig automatisierten Bahn wären insbesondere zu Beginn ohne Fahrgäste. *Silent Testing* im Linienbetrieb erlaubt zwar nicht das Prüfen der Interaktion von Automatisierung und Fahrgast aber der von Fahrzeug und Fahrgast im Allgemeinen. So queren bspw. aussteigende Fahrgäste unmittelbar vor der Bahn die Schienen oder zukünftige Fahrgäste bewegen sich auf Haltestellen und somit die Straßenbahn zu etc.

Aufgrund dieser Vorteile und dem Nachteil der Aufwände von Realtests sowie der ungenügenden Abbildung der realen Welt in Simulationen, wird im Rahmen dieser Arbeit *Silent Testing* als Grundlage zur systematischen Erfassung von Herausforderungen und zur Überprüfung von Lösungsansätzen im Bereich der Straßenbahnautomatisierung verwendet.

### 3.2.2 Existierende *Silent Testing* Methoden

Den *Virtual Assessment of Automation in Field Operation* (VAAFO) genannten Ansatz haben Winner und Wachenfeld erstmalig 2015 vorgestellt. Dabei solle eine Teil-/Automatisierung in einer virtuellen Welt basierend auf der Fahrt eines menschlichen Fahrers ausgeführt werden.<sup>75</sup>

<sup>74</sup> Vires Hexagon: VTD for Railway Industry (2023).

<sup>75</sup> Wachenfeld, W.; Winner, H.: VAAFO - Runtime Validation Method (2015).

Das Ziel des Ansatzes ist das Ableiten von Testszenarien sowie die Bewertung der Sicherheit des OuT als Teil einer Validierung. Die ursprüngliche VAAFO Methode sah das retrospektive Anreichern der virtuellen Welt durch im Fahrtverlauf erst zu einem späteren Zeitpunkt verfügbare Informationen vor. Somit sollten bspw. Fehler in der Verhaltensplanung nicht durch sensorische Fehler wie eine zu späte Detektion von Objekten maskiert werden. Der Ansatz ist in dieser Form nicht praktisch erprobt. 2019 haben Wang und Winner unter Adressierung des Einflusses der offenen Regelschleife sowie der Untersuchung möglicher Vergleichsmetriken VAAFO angepasst.<sup>76</sup> In dieser neuen Form von VAAFO wird auf die retrospektive Anreicherung aufgrund des Aufwandes verzichtet. Im Gegenzug wird dem Fahrzeug in der virtuellen Welt die Ausführung des berechneten Fahrverhaltens ermöglicht und das OuT kann sich so anders verhalten als der menschliche Fahrer. Die vom Realfahrzeug erfassten Objekte der Umgebung werden mittels Koordinatentransformation in den Zustand des virtuellen Fahrzeuges umgerechnet. Da mit der Zeit die virtuelle und reale Welt immer weiter auseinander driften würden, werden mehrere virtuelle Welten mit einem zeitlichen Versatz zyklisch nacheinander gestartet. Jede neue virtuelle Welt wird dabei aus dem zu diesem Zeitpunkt vorherrschenden Zustands des realen Fahrzeuges abgeleitet. Nach einer vorgegebenen Lebenszeit wird die virtuelle Instanz beendet.<sup>76</sup>

Wang definiert zur Identifikation von kritischem Verhalten des OuT sowie zum Ableiten relevanter Testszenarien vier Auslöser. Einerseits wird das Überschreiten kritischer Soll-Beschleunigungen des Realfahrzeuges (insbesondere für das Ableiten von Testszenarien) sowie des OuT in jeder virtuellen Instanz als Auslöser definiert. Andererseits werden dafür Grenzwerte für die zeitliche Änderung dieser kritischen Soll-Beschleunigungen definiert. Damit sollen Falsch-Negative durch zu späte Detektion von Objekten aufgedeckt werden. Die Soll-Beschleunigungen ergeben sich maßgeblich aus den Manövern Bremsen als Alternative zum Ausweichen in autobahnähnlichen Umgebungen.<sup>77a</sup> Die VAAFO Architektur mit den verschiedenen virtuellen Instanzen (vAV 1...N) sowie den Auslösern ist in Abbildung Abb. 3-1 dargestellt.

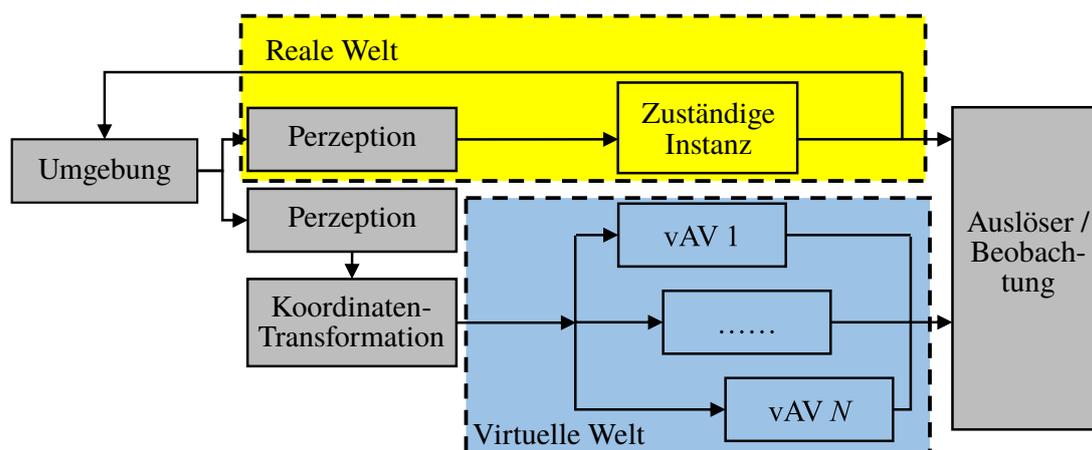


Abbildung 3-1: VAAFO Architektur. Eigene Übersetzung der Darstellung nach Wang.<sup>77b</sup>

76 Wang, C.; Winner, H.: Challenges of Validation and Identification Scenarios (2019), S. 2640

77 Wang, C.: Silent Testing for Validation (2021), a: S. 42, S. 51–55, b: S. 36, c: S. 97 ff., d: S. 124, e: S. 118.

Wang hat das Verfahren exemplarisch auf eine reale Autobahnfahrt von einigen Minuten angewendet und VAAFO so erstmalig plausibilisiert.<sup>77c</sup> Eine Anwendung im Stadtgebiet ist bisher nicht erfolgt. Die Bestimmung der kritischen Soll-Beschleunigungen beschreibt Wang als austauschbarer Teil der VAAFO-Rahmenstruktur.<sup>77d</sup> Der von Wang vorgestellte Stand von VAAFO entspricht also einem Schattensystem mit einer Reduktion des oben genannten Nachteils, dass das OuT seine eigenen Aktionen nicht ausführen kann und sich so stets in dem vom Fahrer aufgeprägten Zustand befindet. Einerseits kann sich durch die Parallelisierung in verschiedenen Instanzen der virtuellen Welt das OuT anders verhalten als der menschliche Fahrer. Andererseits erfolgt jedoch keine andere Interaktion mit umgebenden Verkehrsteilnehmern, also die Beeinflussung derer durch das Verhalten der OuT.<sup>77e</sup>

Koenig et al. verfolgen einen zu VAAFO ähnlichen Ansatz<sup>78, 79a</sup>, bei dem ebenfalls das vorherrschende Szenario der realen Welt als Startbedingung in einer Simulation genutzt wird. Im Gegensatz zu VAAFO wird das Verhalten der umgebenden Fahrzeuge jedoch basierend auf einem neuronalen Netz sowie der rückwirkend beobachteten Intention aus der realen Welt generiert. Somit ist zumindest virtuell eine vollständige Wechselwirkung zwischen dem OuT und anderen Verkehrsteilnehmern möglich. Dabei hängt das Verhalten und insbesondere die Intention der anderen Verkehrsteilnehmer von der Qualität der maschinell gelernten Generierung des Verhaltens ab. Als Auslöser zur Identifikation kritischer Szenarien sowie möglicher Fehler des OuT werden Schwellwerte für die Zeitlücke zwischen Ego und vorausfahrendem Fahrzeug, eine die Beschleunigungen der Fahrzeuge berücksichtigende *TTC*, eine auf maximale Verzögerung ausgelegte *TTB* sowie die Ausnutzung der maximal möglichen Beschleunigungen unter Berücksichtigung des Reibkoeffizienten zwischen Reifen und Fahrbahn definiert.<sup>79b</sup>

Der Autohersteller Tesla nutzt den sogenannten *Shadow Mode*, um ebenfalls ein OuT im Hintergrund, d. h. ohne Eingriff in die Fahrzeugsteuerung zu testen. Das berechnete Verhalten wird mit dem umgesetzten Verhalten des menschlichen Fahrers verglichen. Bei Abweichungen wird das Szenario gespeichert und übermittelt. Die aufgenommenen Daten werden zur Fehleranalyse bzw. als Trainingsdaten zur Verbesserung maschinell gelernter Algorithmen verwendet.<sup>80</sup> Aufgrund des kommerziellen Hintergrundes gibt es jedoch keine Details zum *Shadow Mode*.

Neben der Validierung bzw. Identifikation von Testszenarien existieren verschiedene Ansätze zur online Verifikation. Diese verfolgen das Ziel, dass ein eingesetzter Algorithmus kontinuierlich überprüft wird. In diesem Fall besteht zwar kein *Silent Testing* im oben beschriebenen Sinne, dennoch wird ein OuT mit Kritikalitätsmetriken oder Vergleichen zu vorhandenen anderen Algorithmen überprüft. Bspw. beschreiben Pek, Althoff et al. eine Technik zur Gewährleistung der rechtskonformen Sicherheit einer geplanten Trajektorie.<sup>81</sup> Im Rahmen dieser werden die

---

78 Koenig, A. et al.: Bridging the Gap (2017).

79 Koenig, A. et al.: Passive HAD as a concept for Validation (2018), a: -, b: S. 141.

80 Harris, M.: The Radical Scope of Tesla's Data Hoard (2022), S. 44.

81 Pek, C. et al.: Online verification to prevent accidents (2020).

Trajektorien eines Planungsalgorithmus kontinuierlich gegen eine Belegungskarte bestimmt, die aus den gesetzlich erlaubten Bewegungsmöglichkeiten der umgebenden Objekte erstellt wird.

Eine Überprüfung der Literatur hat keine Hinweise darauf ergeben, dass *Silent Testing* bezüglich automatisierter Fahrfunktionen während des Fahrgastbetriebs von Straßen- oder Vollbahn eingesetzt wird. Im 2023 abgeschlossenen Projekt *Sensor4Rail* wurden auf dedizierten Testfahrten etwa 500 Stunden Sensordaten des Hamburger S-Bahn-Netzes aufgezeichnet, während das System nicht näher spezifiziert „im Stillen“<sup>82</sup> mitlief. Die Daten sollen in einem Datensatz veröffentlicht sowie als Grundlage für einen Szenarien-Katalog werden.<sup>83</sup> Das Versuchsfahrzeug ist mit Sensorik aus dem Kraftfahrzeugbereich und Zugleitsystemen für ATO ausgerüstet, jedoch nicht im regulären Fahrgastbetrieb eingesetzt.

### 3.3 Anwendung auf die Straßenbahn

Zur Verwendung von *Silent Testing* im Bereich der Straßenbahn ist wie für Kraftfahrzeuge auch ein OuT erforderlich. Für den hier aufgezeigten Ansatz muss die Referenzimplementierung nicht vollständig oder ausgereift sein. Aufgedeckte Abweichungen, die nur auf Unzulänglichkeiten der Referenzimplementierung zurückzuführen sind, können erkannt und entsprechend gefiltert werden. Dies ist möglich, da *Silent Testing* in der hier beschriebenen Anwendung nicht zur Validierung von Fahrfunktionen verwendet wird. Grundsätzlich hat die hier beschriebene Methode der Nutzung von *Silent Testing* zur Identifikation von Herausforderungen und Plausibilisierung neuer Lösungsansätze Allgemeingültigkeit und ist unabhängig von der genutzten Referenzimplementierung. Somit kann sie auch zukünftig als Werkzeug des Entwicklungsprozesses des automatisierten Fahrens von Straßenbahnen angewendet werden.

#### 3.3.1 Szenarien mit Abweichungen als Herausforderungen

Um die in 3.1 gestellten Anforderungen an die Methode zu adressieren, werden mithilfe von *Silent Testing* im Umfeld der Straßenbahnen Szenarien identifiziert, bei denen die Referenzimplementierung maßgeblich, entsprechend zu definierender Auslöser, versagt. Dabei werden die identifizierten Szenarien auf zwei unterschiedliche Betrachtungsweisen ausgewertet:

**Makroskopisch** betrachtet werden gefundene Szenarien basierend auf ähnlichen Merkmalen zusammengefasst und gemeinsam statistisch ausgewertet. So lässt sich eine generalisierende Aussage zu Problemfeldern der Automatisierung von Straßenbahnen treffen.

**Mikroskopisch** betrachtet werden identifizierte Szenarien jeweils einzeln im Detail analysiert und ein genaues Verständnis der Ursache der Abweichung erlangt.

---

82 Digitale Schiene: Sensors4Rail testete sensorbasierte Wahrnehmungssysteme (2023).

83 Digitale Schiene: Sensors4Rail Erfolgsprojekt geht zu Ende (2023).

Dies ermöglicht einerseits makroskopisch identifizierte Problemfelder tiefergehend zu analysieren und andererseits zusätzliche Herausforderung der Straßenbahnautomatisierung durch eine Einzelfallbetrachtung zu identifizieren. Letzteres ermöglicht zusätzlich die Identifikation von Herausforderungen, die sich makroskopisch zwar als Abweichungen im Sinne der zu definierenden Auslöser zeigen, deren Ursache jedoch makroskopisch nicht bestimmt werden kann. In dieser Betrachtung sind weiterhin technische Ursachen im Rahmen des Automatisierungssystems auffindbar, indem eine Zuordnung zu einzelnen Verarbeitungsschritten der eingesetzten Algorithmen und Technologien erfolgt.

Mithilfe dieser Betrachtungen werden Herausforderungen bei der Automatisierung von Straßenbahnen bestimmt, wie bspw. ein mögliches Versagen eines im Kraftfahrzeugbereich üblichen Algorithmus des automatisieren Fahrens.

Zusätzlich werden neue Lösungsansätze geprüft, indem diese innerhalb der Referenzimplementierung umgesetzt und mittels *Silent Testing* implizit geprüft werden. Sind die gefundenen Szenarien mit fehlerhaftem Verhalten der Automatisierung nicht durch solche umgesetzten straßenbahnspezifischen Lösungsansätze begründet, so können diese als plausibel betrachtet und für eine weitere Entwicklung der Automatisierung verfolgt werden. Für eine Validierung reicht die im Rahmen der praktischen Anwendung zurückgelegte Strecke jedoch nicht aus, da dies, wie eingangs belegt, bereits im Kraftfahrzeugbereich mehrere Milliarden Testkilometer erfordert.<sup>84, 85</sup> Mutmaßlich ist davon auszugehen, dass auch im Straßenbahnbereich Realfahrten in dieser Größenordnung für eine Validierung erforderlich wären.

Koenig et al. haben in ihrem Ansatz eine Verhaltenssimulation der umgebenden Verkehrsteilnehmer auf der Autobahn durchgeführt, um Wechselwirkungen zu ermöglichen und so die offene Regelstrecke des Schattenmodus virtuell zu schließen. Dafür war jedoch ein Modell zur Verhaltenssimulation erforderlich.<sup>79</sup> Die Erstellung eines solchen Modells ist jedoch insbesondere im urbanen Umfeld mit einer Vielzahl verschiedener Verkehrsteilnehmer, dem variablen Verhalten von Radfahrern und Fußgängern sowie der Variantenvielfalt an möglichem erwarteten Fehlverhalten anderer Verkehrsteilnehmer nicht praktikabel. Weiterhin ist im Gegensatz zu Kraftfahrzeugen bei Straßenbahnen der Kurs aufgrund der Schienenführung vorgegeben. Von Weichen sowie betrieblichen Vorgängen wie dem Öffnen der Türen etc. abgesehen, reduziert sich der Verhaltensraum während der Fahrt auf einen eindimensionalen Freiheitsgrad. Aufgrund dieser Reduzierung des Verhaltensraums wird im Rahmen dieser erstmaligen Anwendung von *Silent Testing* für Straßenbahnen auf die Parallelisierung virtueller Instanzen, wie von Wang<sup>77</sup> in VAAFO durchgeführt, verzichtet. Der Automatisierung wird damit zu jedem Zeitpunkt der Fahrzustand, den der menschliche Fahrer vorgibt, aufgezwungen. Diese Vereinfachung wirkt sich insbesondere auf die Verhaltensplanung aus, da einem von der Automatisierung geplanten Verhalten nicht gefolgt wird. Die sensorische Perzeption von Objekten bleibt davon jedoch unbe-

---

84 Winner, H. et al.: Handbuch Fahrerassistenzsysteme (2015), S. 1174–1177.

85 Bengler, K. et al.: FAS und Automatisiertes Fahren (2021), S. 457–458.

rührt. Da sich diese Arbeit nicht auf die Validierung automatisierter Fahrfunktionen fokussiert, sondern maßgeblich der erstmaligen Identifizierung der Herausforderungen der Automatisierung von Straßenbahnen dienen soll, ist diese Einschränkung annehmbar.

### 3.3.2 Identifikation von relevanten Abweichungen

Zur Identifikation der relevanten Szenarien aus den aufgezeichneten und von der Referenzimplementierung ausgewerteten Daten sind Erkennungsmerkmale in Form von Auslösern zu definieren. Da *Silent Testing* jedoch bisher für Straßenbahnen nicht zur Anwendung kam, ist im vorherigen Kapitel in Forschungsfrage FF. 3 formuliert, wie ein solcher Auslöser für den Vergleich von Mensch und Maschine im Kontext der Straßenbahnen definiert werden kann.

Da wie oben beschrieben durch den Verzicht einer simulativen Umsetzung des geplanten maschinellen Verhaltens das OuT stets dem menschlich herbeigeführtem Fahrzustand entspricht, bewerten übliche Kritikalitätsmetriken wie die *TTC* oder *TTB* lediglich das Verhalten des menschlichen Fahrers. Bremst ein Mensch bspw. früh für ein Objekt, wäre die Kritikalität mit den üblichen Metriken gering. Wenn in diesem Fall die Referenzimplementierung das Objekt fälschlicherweise nicht erfasst hätte, würde dieser Umstand nicht als relevantes Szenario aufgedeckt und die dahinter verborgene Unzulänglichkeit nicht als Herausforderung identifiziert werden. Somit ist ein anderer Indikator anstelle von üblichen Kritikalitätsmetriken erforderlich, der ein Fehlverhalten oder eine Fehlintention des OuT aufdeckt.

Da Straßenbahnen von Berufskraftfahrern geführt werden, verfügen diese aufgrund ihrer Ausbildung und ihrem täglichen Einsatz über ein hohes Maß an Erfahrung. Somit ist davon auszugehen, dass menschliche Straßenbahnfahrer in der Regel situationsangemessen und sicher fahren sowie insbesondere Szenarien des komplexen urbanen Raums sehr gut antizipieren und somit das zukünftige Verhalten anderer Verkehrsteilnehmer gut abschätzen.

Wird das Verhalten des menschlichen Fahrers als grundsätzlich korrekt angenommen, so lässt sich dieses als Referenzverhalten nutzen. Damit ist ein Vergleich zwischen dem Verhalten des OuT und dem des menschlichen Fahrers möglich. Da das Verhalten des OuT in der hier aufgezeigten Anwendung von *Silent Testing* jedoch nicht (virtuell) umgesetzt wird, ist die Intention des OuT zu verwenden. Gleichzeitig ist im aktiven Straßenbahnbetrieb das Verhalten des Fahrers bzw. dessen Intention für eine große Anzahl an Messfahrten nur aus den Zustandsgrößen des Fahrzeuges und dessen Steuereingaben ableitbar. Aus diesem Grund wird das Überschreiten einer kritischen Differenz zwischen der tatsächlich vom Fahrer umgesetzten Beschleunigung der Straßenbahn sowie der berechneten Soll-Beschleunigung der Referenzimplementierung als Auslöser definiert.

$$|\Delta a| = |a_{\text{OuT}} - a_{\text{Fahrer}}| > a_{\text{krit}} \quad (3-1)$$

Wie in Abb. 3-2 dargestellt, wird bei unmittelbarem Überschreiten von  $a_{\text{krit}}$  das geplante Verhalten der Referenzimplementierung als maßgeblich unterschiedlich vom menschlichen Verhalten betrachtet und das vorherrschende Szenario zur weiteren Auswertung markiert.

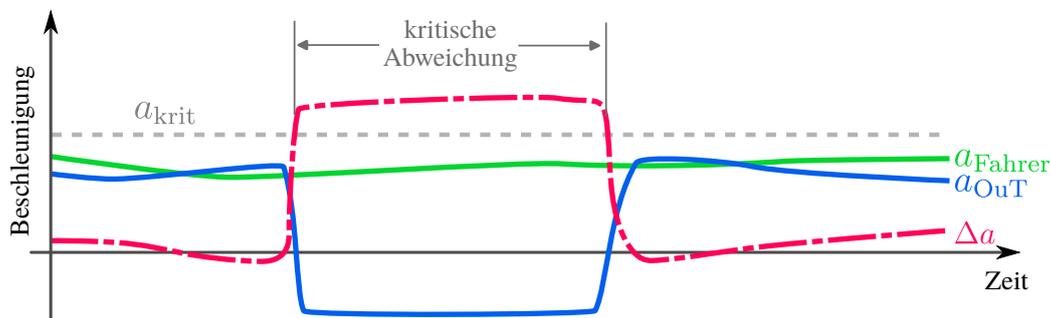


Abbildung 3-2: Beispielhafter Zeitverlauf Beschleunigungsdifferenz.

Die Wahl von  $a_{\text{krit}}$  bildet somit einen Kompromiss zwischen der Sensitivität der Identifizierung von Herausforderungen und der Anzahl an falsch positiven Ergebnissen aufgrund natürlicher Abweichungen. Weiterhin ist bei der Nutzung des Verhaltens als Indikator relevanter Szenarien zu beachten, dass verschiedene zugrunde liegende Beweggründe sowohl bei der Automatisierung als auch beim Fahrer zu einem ähnlichen Verhalten führen können. Wenn zum Beispiel ein Fahrer für das Haltzeichen einer LSA bremst, während die Automatisierung dieses Signal möglicherweise nicht erkannt hat, aber gleichzeitig für einen querenden Fußgänger an derselben LSA abbremst, zeigt dies ein vergleichbares Verhalten. Diese Szenarien würden, mit dem hier aufgezeigten Identifikator nicht erfasst werden.

Da der Vergleich der Beschleunigungen jedoch kontinuierlich durchgeführt wird und das Automatisierungssystem anfahren würde, sobald das Hindernis nicht mehr erkannt wird, ist die exakte zeitliche Überlagerung der Verhalten unwahrscheinlich, aber nicht ausgeschlossen. Dies ist jedoch akzeptabel, da *Silent Testing* hier nicht zur Validierung, sondern zur ersten Identifikation von wesentlichen Herausforderungen der Automatisierung von Straßenbahnen verwendet wird.

Im weiteren Verlauf dieser Arbeit werden identifizierte Abweichungen mit  $\mathcal{A}$  bezeichnet. Diese werden in zwei übergeordnete Kategorien unterteilt. Neben dem Auftreten eines relevanten Szenarios wird anhand des Vorzeichens von  $\Delta a$  zusätzlich eine übergreifende Kategorisierung der Abweichung durchgeführt:

**Negative Abweichung  $\mathcal{A}^-$  :** Diese Abweichungen kennzeichnen sich durch  $\Delta a < 0$ . Wird der Stillstand der Straßenbahn vereinfacht als risikominimaler Zustand betrachtet, so ist eine Verzögerung des Fahrzeuges bzw. eine weniger starke Beschleunigung durch die Automatisierung nicht als sicherheitskritisch bezüglich externer Kollisionen, sondern vornehmlich als Komfortproblem einzustufen. Ein gehäuftes Auftreten ist dennoch nicht akzeptabel, da der eigentliche Fahrauftrag nicht erfüllt werden würde. Auch ist zu berücksichtigen, dass bereits mit menschlichem Fahrer etwa 5 % aller Straßenbahnunfälle mit Personenschäden

auf Sturzunfälle von Fahrgästen nach mutmaßlich starken Bremsungen zurückzuführen sind.<sup>86</sup> Daher sind auch Szenarien, in denen bspw. aufgrund fälschlich detektierter Phantomobjekte eine Gefahrenbremsung ausgelöst wird, als relevant zu betrachten und als Herausforderung zu lösen.

**Positive Abweichung  $\mathcal{A}^+$**  : Diese Abweichungen weisen sich durch  $\Delta a > 0$  aus. Gegenüber  $\Delta a < 0$  handelt es im Wesentlichen um sicherheitskritisches Versagen. Insbesondere der Quadrant II in nachfolgender Abb. 3-3 ist von höchster Wichtigkeit, da bei diesen Szenarien der Fahrer bremst und das OuT beschleunigen würden. Der Fahrer könnte bspw. für ein Hindernis bremsen, welches die Automatisierung (noch) nicht erfasst oder fälschlich absichtlich ignoriert hat.

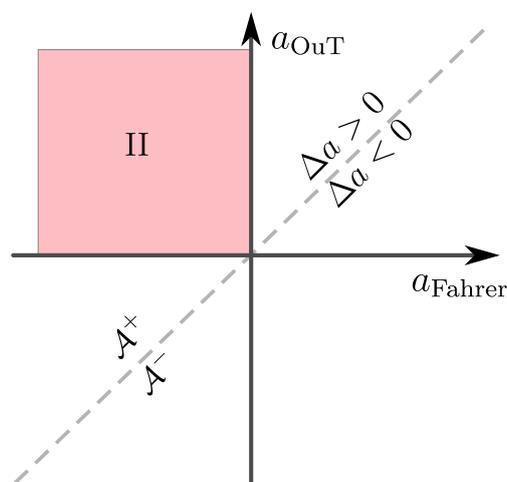


Abbildung 3-3: Beschleunigungsdifferenz mit kritischer Abweichung.

Obwohl der menschliche Fahrer als Berufskraftfahrer über ein großes Maß an Können und Erfahrung verfügt, sind Fehlverhalten dennoch nicht auszuschließen und in einem längeren Betrachtungszeitraum sogar zu erwarten. Da *Silent Testing* jedoch nicht als statistisch binäres Versagenskriterium ohne weitere Prüfung eingesetzt wird, sondern aus den identifizierten Szenarien Herausforderungen abzuleiten sind, ist dieser Nachteil durch die anschließende Auswertung zu kompensieren. In der mikroskopischen Betrachtung werden fälschlich erfasste Szenarien durch eine Einzelfallbetrachtung ausgeschlossen.

Werden jedoch aufgrund der Vielzahl aller identifizierten Szenarien diese nicht alle manuell einzeln betrachtet und so überprüft, wäre die gesamtheitliche makroskopische Betrachtung davon beeinflusst. Daher ist im Rahmen der makroskopischen Betrachtung die Auswertung nur als Indikator und nicht als absolutes Maß zu verstehen und bspw. gebildete makroskopische Gruppen von Herausforderungen nicht gegeneinander in der Zahl des Auftretens zu vergleichen. Vielmehr muss die Einzelfallbetrachtung vermutete Herausforderungen bestätigen oder verwerfen.

<sup>86</sup> Grießbach, A. et al.: Maßnahmen Unfälle mit Straßenbahnen (2016), S. 85, 114.

Im Gegensatz zu den in der Literatur beschriebenen Ansätzen von *Silent Testing* im Kraftfahrzeugbereich, mit ausschließlich objektbezogenen Kritikalitätsmetriken wie der *TTC* oder *TTB*, wird durch den Vergleich des menschlichen und maschinellen Verhaltens eine umfassendere Bewertung der Automatisierung ermöglicht. So wird neben der maschinellen Reaktion auf umgebende Objekte auch das Verhalten durch weitere Einflüsse wie LSA, Haltevorgängen an Haltestellen, „unbekannte Unbekannte“ etc. implizit berücksichtigt und damit verbundene Herausforderungen identifiziert. Nachteilig an diesem Vorgehen ist, dass eine unmittelbare Zuordnung zwischen identifizierter Abweichung und auslösendem Grund nicht immer möglich ist. Im Falle von  $\Delta a < 0$  kann unter der Prämisse eines nachvollziehbaren Planungsalgorithmus (also keine Verfahren wie Ende-zu-Ende-Lernen) eine explizite Begründung für die Abweichung des Verhaltens gegeben werden. Diese Begründung lässt sich makroskopisch als erste Kategorisierung und Trennung der identifizierten Szenarien nutzen. Daher wird in der in Kapitel 4 beschriebenen Referenzimplementierung neben der von der Automatisierung bestimmten Soll-Beschleunigung auch die Begründung für diese Beschleunigung sowie zugehörige Metainformationen (Position der Objekte etc.) ausgegeben.

Für  $\Delta a > 0$ , also einem Bremsen oder weniger starkem Beschleunigen des Fahrers, gibt es zwar für den Planungsalgorithmus der Automatisierung einen eindeutigen Grund für das gewählte Verhalten, jedoch ist dieser nicht zwangsläufig der Grund für das Verhalten des menschlichen Fahrers. Geht der Planungsalgorithmus bspw. von einer freien Strecke ohne Hindernisse aus und regelt auf Höchstgeschwindigkeit, wäre dies nicht der Grund der Abweichung, falls der menschliche Fahrer für ein nur von ihm wahrgenommenes Hindernis bremst. Da die Beweggründe des menschlichen Fahrers nicht bekannt sind, ist es in diesen Fällen erforderlich, eine Detailanalyse jeder Abweichung in Form der mikroskopischen Betrachtung durchzuführen. Im Rahmen dieser Detailanalysen lassen sich, Erkennbarkeit in den Kameradaten und nachvollziehbares Verhalten vorausgesetzt, die Beweggründe der menschlichen Fahrer und somit die Ursachen der Abweichungen identifizieren.

Sowohl mit  $\Delta a > 0$  wie auch  $\Delta a < 0$  identifizierte Szenarien können mit weiteren Metriken gefiltert werden. Dies kann einerseits zur expliziten Suche nach einer vermuteten Herausforderung oder dem Ausfiltern bekannter Unzulänglichkeit der Automatisierung genutzt werden, andererseits könnte eine vollständige mikroskopische Betrachtung aufgrund der Vielzahl der gefundenen Szenarien zu aufwendig sein. Denkbar sind bspw. zusätzliche Filter wie der Einsatz der Gefahrenbremse durch den menschlichen Fahrer oder Gruppierungen nach Art und Ort. Diese Filterung muss bedarfsgerecht an die Gemeinsamkeiten der identifizierten Szenarien und den Untersuchungszweck angepasst werden und erfolgt im Rahmen dieser Arbeit als Teil der praktischen Auswertung in Kapitel 5. Grundsätzlich ist die einleitende Forschungsfrage FF. 3 bezüglich der Gestaltung einer Vergleichsmetrik durch die aufgezeigte Anwendung mittels  $\Delta a$  beantwortet. Die damit verbundenen praktischen Herausforderungen zeigen sich jedoch erst im Rahmen der Anwendung in Kapitel 5. Dafür ist die Parametrisierung von  $a_{\text{krit}}$  erforderlich, welche im nächsten Abschnitt beschrieben wird.

### 3.3.3 Parametrisierung $a_{\text{krit}}$

Je niedriger  $a_{\text{krit}}$  gewählt wird, desto mehr korrekt identifizierte (richtig-positive) Szenarien mit Unzulänglichkeiten der Automatisierung werden identifiziert, womit auch die Zahl nicht entdeckter Abweichungen (Falsch-Negative) reduziert wird. Allerdings kann  $a_{\text{krit}}$  nicht beliebig klein gewählt werden, da hiermit auch die Zahl der falsch positiv identifizierten Szenarien steigt. Also solcher Szenarien, bei denen zwar eine Abweichung zwischen den Beschleunigungen von Fahrer und Automatisierung vorliegt, dies aber nicht auf eine Unzulänglichkeit oder Herausforderungen zurückzuführen ist. Es werden zwei wesentliche Ursachen für falsch positiv identifizierte Szenarien erwartet: Auch bei identischem Szenario würde derselbe Fahrer das Fahrzeug auch bei dem gleichen Vorhaben nicht identisch führen. Diese Varianz in der Umsetzung des geplanten menschlichen Verhaltens sowie der eigentlichen Auswahl des Verhaltens wird nochmals dadurch verstärkt, dass über den Aufnahmezeitraum hinweg verschiedene Fahrer mit jeweils unterschiedlichen Fahrweisen eingesetzt werden. Als zweite wesentlich Ursache für falsch positiv identifizierten Szenarien wird erwartet, dass es zwar ein unter verschiedenen Bewertungskriterien bestimmtes optimales Verhalten für ein Szenario geben kann, dies aber im Umkehrschluss nicht bedeutet, dass alle anderen Verhalten falsch sind. Beispielfähig könnte ein Straßenbahnfahrer deutlich langsamer fahren, um einem Bus die Ausfahrt aus einer Haltestelle zu ermöglichen. Genauso wäre es aber auch regelkonform, wenn der Fahrer mit der zulässigen Höchstgeschwindigkeit weiterfährt und der Bus warten müsste.

Ohne praktische Überprüfung und Identifikation solcher Szenarien lässt sich letzterer Abweichungsgrund weder in Häufigkeit noch in der Auswirkung auf die Ego-Beschleunigung des Fahrzeuges abschätzen. Daher wird zur Wahl von  $a_{\text{krit}}$  die Varianz des menschlichen Verhaltens zu einem a-priori bekannten und leicht zu identifizierbarem Szenario betrachtet. Die Untersuchung mehrfacher menschlicher Wiederholungen desselben Szenarios ermöglicht die Bestimmung der Streuung.  $a_{\text{krit}}$  wird basierend darauf größer als diese Streuung gewählt, da sonst unter Anwendung von *Silent Testing* die Zahl der falsch positiv identifizierten Szenarien aufgrund der Varianz des menschlichen Verhaltens zu hoch wäre. Aufgrund der Variationen beim Auftreten von Hindernissen gestaltet sich die Identifikation von reproduzierbaren Szenarien als herausfordernd. Daher wird als erster Vorschlag im Rahmen dieser Arbeit das Einfahren in eine Haltestelle zur Bestimmung der Varianz des menschlichen Verhaltens untersucht. Es ist eine Haltestelle gewählt, bei welcher der Fahrer auf einem unabhängigen Bahnkörper ohne Objekte im Fahrschlauch auf einem geraden Abschnitt einfährt. Es sollte sich somit um ein vergleichsweise einfaches Szenario mit hoher Reproduzierbarkeit des Verhaltens handeln. Damit die gleichen Anfangsbedingungen gelten, sind alle Messungen ausgewählt, die bei einem willkürlichen Abstand von 150 m von der Haltestelle eine Geschwindigkeit von  $\pm 3$  km/h der Mediangeschwindigkeit aller verfügbaren Messungen an dieser Stelle aufweisen. Die Mediangeschwindigkeit bei diesem Abstand beträgt 44,7 km/h. Aus allen 268 verfügbaren Messungen zu dieser Haltestelle sind somit 85 Messungen ausgewählt. Nachfolgende Abb. 3-4 zeigt den Verlauf der Beschleunigungen entlang des Abstandes zur Haltestelle für diese 85 Messungen.

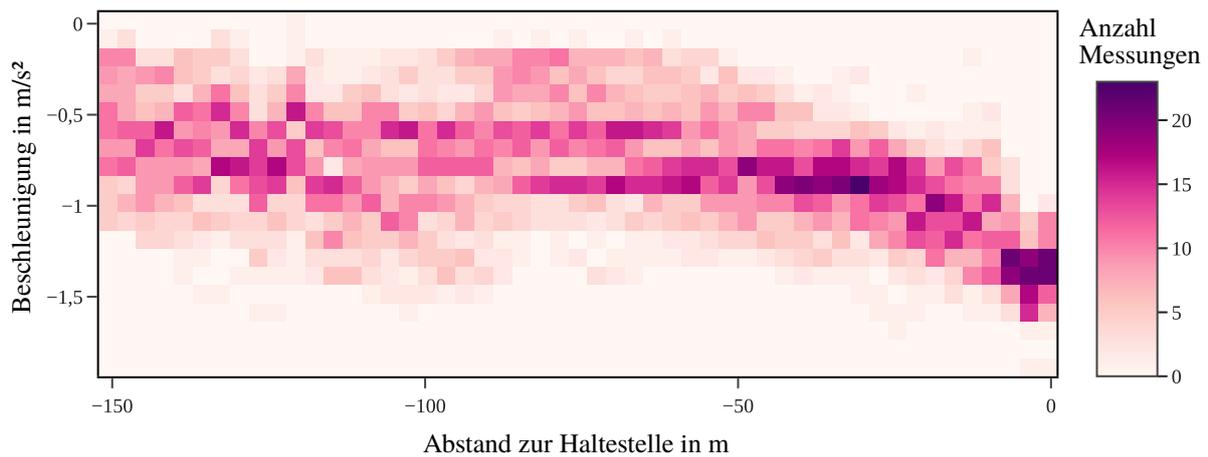


Abbildung 3-4: Streuung der Beschleunigen von 85 Messungen bei einer Haltestelleneinfahrt.

Das Verhalten des Anhaltens sollte unter der Voraussetzung, dass keine Störgrößen wie Hindernisse vorhanden sind, maßgeblich nur von der Geschwindigkeit der Bahn und dem Abstand von der Haltestelle abhängen. Obwohl alle 85 Messungen mit nahezu gleicher Anfangsgeschwindigkeit das Manöver beginnen, ist der Verlauf der Beschleunigungen bis zu etwa  $1,5 \text{ m/s}^2$  unterschiedlich. Dabei ist zu beachten, dass frühes und starkes Verzögern zu geringeren Verzögerungen bei kleinerem Abstand führt. Daher sind in Abb. 3-5 aus allen verfügbaren Messungen für fünf verschiedene Abstände diejenigen Messungen dargestellt, die an diesen Abständen  $\pm 3 \text{ km/h}$  der Mediangeschwindigkeit an diesen Stellen entsprechen. Somit wird nicht der Verlauf, sondern der Unterschied der Beschleunigungen bei gleichen Randbedingungen dargestellt.

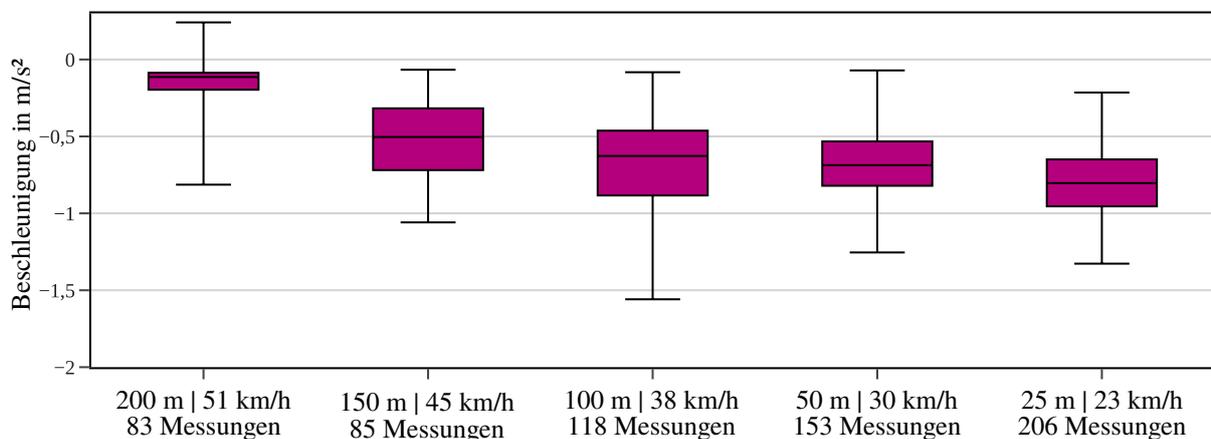


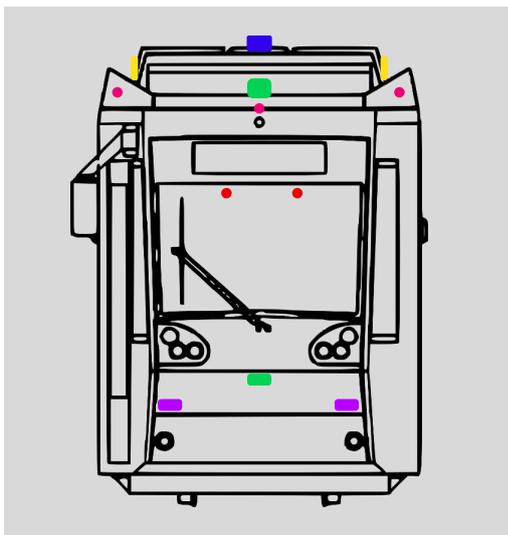
Abbildung 3-5: Boxplot der Streuung von Haltestelleneinfahrten.

Die größte Streuung mit etwa  $1,5 \text{ m/s}^2$  tritt bei einem Abstand von 100 m zur Haltestelle auf. Bei dem Anhalten an einer Haltestelle handelt es sich wie zuvor beschrieben um ein vergleichsweise einfaches Manöver. Insbesondere für Hindernisse ist eine größere Varianz im menschlichen Verhalten zu erwarten. Der Schwellwert zur Identifikation von Abweichungen zwischen Mensch und OuT wird daher auf  $a_{\text{krit}} = 2,0 \text{ m/s}^2$  festgelegt. Dieser Wert ist als erster Vorschlag zu verstehen und kann zukünftig durch weitere Untersuchungen angepasst werden.

### 3.3.4 Umsetzung der Methode im Rahmen dieser Arbeit

Wie zuvor beschrieben, ist für die Anwendung von *Silent Testing* ein OuT erforderlich, weshalb im Rahmen dieser Arbeit eine Referenzarchitektur zur Automatisierung von Straßenbahnen erarbeitet und prototypisch implementiert ist. Aufgrund der Überschneidungen der Einsatzgebiete folgt die Referenzarchitektur der Prämisse, dass möglichst viele Auswertemethoden aus dem Bereich des automatisierten Fahrens von Kraftfahrzeugen verwendet werden sollten. Neben Algorithmen des automatisierten Fahrens von Kraftfahrzeugen werden zusätzlich straßenbahnspezifische Lösungsansätze umgesetzt, bei denen eine Reduzierung des Automatisierungsaufwandes möglich scheint sowie aufgrund der Andersartigkeit zu Kraftfahrzeugen keine wiederverwendbaren Methoden bestehen. Das entworfene Automatisierungssystem ist nachfolgend in Kapitel 4 beschrieben.

Neben einem Automatisierungssystem bedarf es zur Anwendung von *Silent Testing* auch Realdaten. Zur Erhebung dieser Daten im regulären Fahrbetrieb wurde im Rahmen dieser Arbeit und des Forschungsprojektes MAAS<sup>87</sup> eine bestehende Straßenbahn des Darmstädter Verkehrsbetriebs HEAG mobilo GmbH umgerüstet. Dazu wurde die Straßenbahn mit im Kraftfahrzeugbereich üblichen Sensoren des automatisierten Fahrens ausgestattet. Dabei wurden ähnlich zu anderen Versuchsaufbauten automatisierter Fahrzeuge verschiedene Technologien (Lidar, Radar, Kamera) eingesetzt, um die spezifischen Vorteile (Auflösung, Geschwindigkeitsmessung etc.) zu kombinieren. Nachfolgende Abb. 3-6 zeigt den Versuchsträger sowie die Anordnung der Sensoren. Die Straßenbahn wurde mit zwei Radarsensoren ■, zwei Lidarsensoren ■, zwei Kameras hinter der Frontscheibe für die Fernsicht ●, drei Kameras mit Fischaugenobjektiven im Dachbereich für die Nahsicht ●, einem GNSS Empfänger ■ sowie Mobilfunk ■ ausgestattet.



(a) Schematische Anordnung der Komponenten



(b) Umsetzung an der „MAASBahn“<sup>88</sup>

Abbildung 3-6: Sensorsetup und Komponenten des Versuchsfahrzeugs.

<sup>87</sup> HEAG: Forschungs-Straßenbahn vorgestellt (2019).

Die Auslegung der Anordnung erfolgte unter dem Ziel, sowohl Fern- wie auch Nahbereich mit den im Kraftfahrzeugbereich üblicherweise eingesetzten Sensorarten Radar, Lidar und Kamera zu erfassen.<sup>89</sup> Gleichzeitig mussten verschiedene restriktive Vorgaben bezüglich der Einbauorte wie der Schutz von Passanten im Fall einer Kollision berücksichtigt werden. Die genauen Fabrikate und Eigenschaften der Umfoldsensorik<sup>90</sup> sind nachfolgend in Tabelle 3-1 aufgeführt.

Tabelle 3-1: Übersicht verbaute Umfoldsensoren.<sup>91, 92, 93, 94, 95</sup>

Sensor	Anzahl	Verbauort	Eigenschaften
<b>Velodyne VLP-32C</b> Lidar	1	Dachkante mittig	32 vertikale Ebenen 40° vertikales FoV 360° horizontales FoV Reichweite 200 m
<b>Ibeo Scala</b> Lidar	1	Frontschürze mittig	4 vertikale Ebenen 3,2° vertikales FoV 145° horizontales FoV Reichweite 327 m
<b>Continental SRR52x</b> Radar	2	Frontschürze links Frontschürze rechts	15° vertikales FoV 150° horizontales FoV Reichweite 100 m
<b>Fernsichtkamera</b> Kamera	2	Frontscheibe links Frontscheibe rechts	66,9° vertikales FoV 82,4° horizontales FoV 2056 × 1542 Pixel
<b>Nahsichtkamera</b> Kamera	3	Dachkante links Dachkante mitte Dachkante rechts	180° vertikales FoV 180° horizontales FoV 2056 × 1542 Pixel

Neben dem Einbau der Sensorik wurde eine Schnittstelle zum Fahrzeug geschaffen, die Zugriff auf bereits vor der Umrüstung vorhandene Ego-Zustandsdaten wie die Geschwindigkeit und die Steuereingaben des Fahrers ermöglicht. Die aufgezeigte Umrüstung hat entsprechend *Silent*

88 Foto ursprünglich von Patrick Pintscher.

89 Im Projekt wurden weitere Sensoren verbaut, die aufgrund sensorseitig eingeschränkter Schnittstellen jedoch nicht zur Anwendung von *Silent Testing* eingesetzt wurden.

90 Ohne weitere Sensoren wie GNSS, Mobilfunk etc.

91 Velodyne: Datenblatt Ultra Puck VLP-32C (2017).

92 ibeo: Whitelabel Datenblatt Scala B3.0 (2023).

93 Continental: Produktwebseite SRR52x (2023).

94 Edmund Optics: Datenblatt 68670EP (2017).

95 Lensagon: Datenblatt BF10M19828S118 (2017).

*Testing* keinen Einfluss auf die Fahrfunktion. Die Versuchsbahn wird daher weiterhin mit menschlichem Fahrer im normalen Linienbetrieb mit Fahrgästen eingesetzt. Eine solche Erhebung von Realdaten ist insbesondere im Bereich der Straßenbahn erstmalig und stellt eine wesentliche Erweiterung der bisherigen Forschung dar.

Grundsätzlich ist für die Anwendung von *Silent Testing* keine Aufzeichnung von Sensordaten erforderlich, da die Referenzimplementierung während der Fahrt als online Schattensystem ausgeführt werden kann. Dies hat den Vorteil, dass kein großer Datenspeicher für die Sensordaten benötigt wird, jedoch den Nachteil, dass die Auswertung nur für die Dauer der Fahrt möglich ist. Somit können nachträgliche Änderungen an der Implementierung nicht erneut auf den gleichen Daten evaluiert werden. Aufgrund der Erstmaligkeit dieses Ansatzes und erwartbaren Problemen bei der Implementierung der Referenzarchitektur erfolgte im Rahmen dieser Arbeit eine Aufzeichnung der Sensordaten. Die mit der im Linienbetrieb befindliche Versuchsbahn erhobenen Daten wurden nach der Aufnahme mit der in Kapitel 4 beschriebenen Referenzimplementierung auf dem Hochleistungsrechner „Lichtenberg“ der TU Darmstadt als offline Schattensystem ausgewertet. Durch die Anwendung der Methode in Kapitel 5 wurden relevante Szenarien sowie zugehörige Herausforderungen identifiziert.

Die Aufnahmen erstrecken sich über das gesamte Straßenbahnnetz von Darmstadt, jedoch sind aufgrund von Baustellen vereinzelte Strecken unterrepräsentiert. Obwohl Darmstadt nur eine einzelne Stadt ist und nur ein Forschungsfahrzeug eingesetzt wurde, lassen sich dennoch allgemeingültige straßenbahnspezifische Herausforderung identifizieren. Darmstadt verfügt über die wesentlichen Merkmale wie unabhängige, besondere sowie straßenbündige Bahnkörper im urbanen sowie ländlichen Raum in verschiedenen Verkehrsumgebungen und unterschiedlichen Materialien zwischen den Schienen. Weiterhin umfasst auch die Witterung in Darmstadt vielfältige Merkmale wie Sonnenschein, Schnee, Nebel, aber auch Extremereignisse wie Starkregen. Die Anwendung der vorgestellten Methode in weiteren Städten ist möglich und würde die Identifikation vor allem städtespezifischer Herausforderungen ermöglichen. Aufgrund der Komplexität des Einsatzes der aufgebauten Versuchsbahn in anderen Städten ist dies jedoch nicht Teil dieser Arbeit.

## 4 Referenzarchitektur und -implementierung der Straßenbahnautomatisierung

Wie in Kapitel 3 aufgezeigt, ist zur Anwendung von *Silent Testing* ein System erforderlich, welches die Automatisierung der Straßenbahn zumindest in Teilen abbildet und so einen Vergleich von Mensch und Maschine ermöglicht. Im Rahmen dieser Arbeit wird daher eine Referenzarchitektur der Straßenbahnautomatisierung entworfen und als Referenzimplementierung umgesetzt. Die Referenzimplementierung dient dabei einerseits als Konzeptnachweis der Anwendbarkeit von *Silent Testing* im Bereich der Straßenbahnautomatisierung, andererseits werden damit erstmalig systematisch Herausforderungen im Bereich der Straßenbahn identifiziert und umgesetzte Lösungsansätze plausibilisiert. Zur Ableitung funktionaler Anforderungen an die Automatisierung und einem darauf basierenden Entwurf der Referenzarchitektur werden nachfolgende Prämissen getroffen:

**Fokus Fahraufgabe:** Wird der Betrieb einer Straßenbahn betrachtet, übernimmt der Fahrer neben der reinen Fahrzeugführung eine Vielzahl weiterer Aufgaben. So ist er bspw. für die Einhaltung des Fahrplans verantwortlich, steuert und überwacht den Fahrgastwechsel, informiert Fahrgäste bei Bedarf, löst Störungen und kontrolliert außerhalb der Fahrerkabine den Zustand des Fahrzeuges an Endhaltestellen. Die nachfolgend aufgestellten Anforderungen sowie Umsetzung dieser fokussiert sich alleinig auf die Herausforderungen der Fahrzeugführung, d. h. der reinen Fahraufgabe. Die Übernahme der weiteren Aufgaben durch ein Automatisierungssystem wird im Rahmen dieser Arbeit nicht betrachtet. Für einen realen Betriebseinsatz einer Automatisierung wären diese entsprechend zu identifizieren und umzusetzen. Ein Teil dieser Anforderungen überschneidet sich mit automatisierten Metros, ist dort bereits umgesetzt und kann daher für die Straßenbahnautomatisierung adaptiert werden.

**Ohne Änderung der Infrastruktur:** Anpassungen der bestehenden Infrastruktur oder der Aufbau neuer Infrastrukturelemente sind kostenintensiv und werden in anderen Domänen<sup>96, 97</sup> nach Möglichkeit vermieden. Aus diesem Grund werden zunächst Änderungen an der Infrastruktur zum Zweck der Automatisierung ausgeschlossen. Für die Automatisierung der Straßenbahn wird daher die Anforderung gestellt, dass sie auf die bestehende — für den menschlichen Fahrer ausgelegte — Infrastruktur aufbauen muss. Dies bedeutet jedoch im Umkehrschluss nicht, dass mit der hier durchgeführten Anwendung von *Silent Testing* nicht genau ein solcher Bedarf für Änderungen an der Infrastruktur aufgezeigt werden kann. Weichen, die nur händisch vom Fahrer mit einem Weicheisen zu legen sind, werden

---

96 Hagemeyer, F. et al.: Automatisiertes Fahren auf der Schiene (2021), S. 3.

97 Mihalj, T. et al.: Road Infrastructure Challenges Faced by Automated Driving (2022).

ohne Änderungen als nicht automatisierbar betrachtet. Diese Art von Weichen ist zumeist jedoch nur noch auf Betriebshöfen oder in Ausnahmefällen (Störungen) im Fahrgastbetrieb anzutreffen und wird aus diesem Grund nicht weiter berücksichtigt.

**ODD Straßenbahnnetz Darmstadt und Umgebung:** Straßenbahnen weisen häufig Besonderheiten wie Ausnahme- oder Zusatzregeln im Rahmen ihres lokalen Einsatzgebietes auf. Wie zuvor im Kapitel zur Methodik angeführt, werden mithilfe von *Silent Testing* neben städtespezifischen insbesondere die wesentlichen und somit auch für andere Städte gültigen Herausforderungen der Straßenbahnautomatisierung identifiziert. Darunter sind solche Herausforderung aufgefasst, die sich aus der Besonderheit der Straßenbahn als Verkehrsmittel ergeben, bisher jedoch nicht systematisch identifiziert sind und auch für den Einsatz in anderen Betriebsgebieten gelöst werden müssen. Die Stadt Darmstadt charakterisiert sich durch ein repräsentatives Straßenbahnnetz und umfasst eine Vielzahl unterschiedlicher straßenbahnüblicher Szenerien wie verschiedene Gleiskörper, Überlandfahrt, Innenstadt, Mitfahrt im Straßenverkehr, verschiedene Bodenbeläge etc. Die Anwendung der *Silent Testing* Methode in anderen Städten würde insbesondere die in diesen Städten gültigen spezifischen Herausforderungen identifizieren.

**ODD Regelbetrieb mit Fahrgästen:** Die vorliegende Referenzarchitektur wird für den Regelbetrieb der Straßenbahn mit Fahrgästen entworfen. Dies bedeutet, dass in dieser Umsetzung aufgrund des seltenen Auftretens und dem Fokus dieser Arbeit auf grundlegende Herausforderungen der Automatisierung folgenden Situationen nicht betrachtet werden:

- Störungen am Fahrzeug
- Fahrten in Betriebshöfen, Rangierfahrten nach Anlage 4 der BOStrab
- Im Betrieb mit Fahrgästen nicht übliche Fahrzeugbewegungen wie bspw. Rückwärtsfahren, das Auffahren von Weichen nach Anlage 4 Signal W 14 der BOStrab oder das Legen einer Weiche mit einem Weicheisen
- Erkennung sowie das Verhalten im Falle von Unfällen oder Entgleisungen

**Fahren auf Sicht:** Das *Fahren auf Sicht* nach BOStrab bedeutet, dass der Fahrer die Strecke vor sich einsehen muss und die Geschwindigkeit so wählt, dass er innerhalb der Sichtweite anhalten kann. Demgegenüber steht das Fahren mit einer Zugsicherungsanlage nach § 22 BOStrab, welche auch Geschwindigkeiten mit einem Anhalteweg größer der Sichtweite zulässt. Zugsicherungsanlagen erlauben vereinfacht das Einstellen und Verschließen von Weichen, das Übermitteln von Fahraufträgen von einer zentralen Sicherheitsinstanz sowie die Überwachung und Beeinflussung der Bahn unter Erfassung der Gleisbelegung durch andere Straßenbahnen sowie die Erfassung von sicherheitsrelevanten Zuständen der Infrastruktur, wie es bei Bahnübergängen der Fall ist. Wie in Kapitel 2 aufgezeigt, gibt es bereits Metros nach GoA 4, die einen Betrieb ohne Fahrer ermöglichen. Hierbei handelt es sich um zentrale Sicherheitsarchitekturen. Alle Verkehrsteilnehmer sowie Zustände

der Infrastruktur dieser Systeme sind zentral erfassbar, sodass auch Fahrfreigaben zentral erteilt und entzogen werden. Für den Betrieb einer Straßenbahn im öffentlichen Straßenverkehr, in offen zugänglichen Bereichen wie auf Überlandfahrten sowie in Innenstädten mit Fußgängern und Radfahrern ist jedoch eine dezentrale Sicherheitsarchitektur zwingend erforderlich. Die Straßenbahn muss in diesen Szenen selbständig in der Lage sein, relevante umgebende Verkehrsteilnehmer, weitere Hindernisse sowie die meist nicht an eine Zugsicherung angeschlossenen LSA<sup>98</sup> wahrzunehmen und basierend darauf eigenständig eine Fahrentscheidung zu treffen — so wie es derzeit auch vom menschlichen Fahrer als dezentrale Funktion umgesetzt wird. Daher wird im Rahmen dieser Arbeit eine dezentrale Referenzarchitektur erarbeitet und klassische Zugsicherungen wie auch modernere CBTC-basierte Zugsicherungsanlagen zunächst nicht betrachtet. Eine Integration der entworfenen Architektur in Zugsicherungsanlagen ist möglich, jedoch nicht Voraussetzung.

## 4.1 Funktionale Verhaltensanforderungen

Da es für Straßenbahnen jedoch keine allgemeingültige Beschreibung der Anforderungen an eine Automatisierung oder Versuche diesbezüglich gibt, wurde einleitend in Forschungsfrage FF. 4 nach dem Funktionsumfang einer Automatisierung gefragt. Zur Beantwortung dieser Forschungsfrage und somit Schaffung einer Grundlage für den systematischen Entwurf einer Referenzarchitektur werden nachfolgend zunächst die Anforderungen an die Automatisierung in Form eines Soll-Verhaltens definiert.

Im Kraftfahrzeugbereich existieren zur Erfassung der Anforderungen und der notwendigen Fähigkeiten eine Vielzahl verschiedener Ansätze. Censi et al. formulieren bspw. das Verhalten automatisierter Pkw basierend auf einem Satz an Regeln, die in einem nach Priorität sortiertem Regelbuch festgehalten werden. Die Regeln können dabei aus verschiedenen Quellen stammen, wie bspw. aus Gesetzen und Verordnungen, ethischen Betrachtungen oder Regeln des gesunden Menschenverstandes.<sup>99</sup> Stolte et al. legen im Rahmen einer *System-Theoretic Process Analysis* (STPA) unsichere Kontrollhandlungen fest. Diese dienen anschließend zur Ableitung darauf basierender Sicherheitsziele für die Funktionen.<sup>100</sup> Glatzki und Lippert betrachten den Verhaltensraum aus Sicht der Szenerie und beschreiben diesen als Zusammensetzung aus vier Verhaltensattributen: Geschwindigkeit, Begrenzungen, Reservierung des Aufenthaltsorts sowie der Erlaubnis zu überholen.<sup>101</sup> Dabei wird in der *Behavior-Semantic Scenery Description* (BSSD)

---

98 Abhängig der örtlichen Gegebenheiten und des Betreibers sind einzelne LSA in eine gegebenenfalls vorhandene Zugsicherung eingebunden. Eine flächendeckende Einbindung ist in Deutschland derzeit unüblich aber nicht ausgeschlossen.

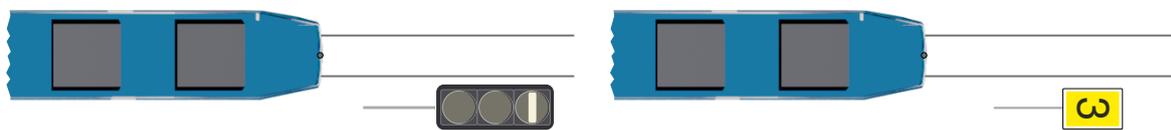
99 Censi, A. et al.: Liability, Ethics, and Culture-Aware Behavior Specification (2019).

100 Stolte, T. et al.: Safety goals and functional safety requirements (2016).

101 Glatzki, F. et al.: BSSD (2021).

genannten Beschreibung nur das Grenzverhalten berücksichtigt. Sofern alle Grenzen in Form von Einschränkungen des Verhaltens (bspw. Halt an einem Stoppschild) berücksichtigt werden, sind die sicherheitsrelevanten funktionalen Anforderungen einer beschriebenen Szenerie erfasst. Dies ist jedoch nicht hinreichend für alle sicherheitsrelevanten funktionalen Anforderungen eines OuT, da bspw. eine von der Szenerie unabhängige allgemeine Kollisionsvermeidung von BSSD nicht berücksichtigt wird. Den genannten Ansätzen ist gemein, dass Regeln, Kontrollhandlungen oder Verhalten durch eine Analyse des Status Quo, d. h. basierend auf dem Führen und Straßenverkehr mit menschlichem Fahrer, abgeleitet wird.

Da in der vorhandenen Literatur keine spezifischen Beschreibungen hinsichtlich der Anforderungen an die Automatisierung von Straßenbahnen oder vergleichbare Ansätze zur Ableitung solcher Anforderungen vorliegen, werden die funktionalen Anforderungen an die Automatisierung der Straßenbahn basierend auf dem extern beobachtbaren Verhalten mit menschlichem Fahrer abgeleitet. Dabei werden die oben aufgeführten Prämissen berücksichtigt. Dies wirkt sich in erster Linie auf eine Reduzierung der Verhaltensvielfalt aus. Das Soll-Verhalten wird in Anlehnung an die Beschreibung nach BSSD als Grenzverhalten erfasst. Abb. 4-1 zeigt mit dem Halt an einer LSA sowie der Anpassung der Streckenhöchstgeschwindigkeit zwei Beispiele limitierenden Grenzverhaltens für die Straßenbahn. Im Gegensatz zu der rein auf Szenerien und damit örtlich fokussierten Betrachtungsweise von BSSD werden jedoch unabhängig der Szenerie zusätzliche Anforderungen an das Grenzverhalten — wie das überall gültige Vermeiden von Kollisionen mit Hindernissen — ergänzt.



(a) Einschränkung der Weiterfahrt durch LSA mit F0

(b) Limitierung der Geschwindigkeit 30 km/h

Abbildung 4-1: Beispiele für limitierendes Grenzverhalten der Straßenbahn im übertragenen Sinne von BSSD.

Neben dem sicherheitsrelevanten Grenzverhalten sind weitere Anforderungen wie bspw. eine komfortable oder energiesparende Fahrweise möglich. Auch wenn ein solches Verhalten für eine Automatisierung langfristig erstrebenswert oder gar für den Betrieb mit Fahrgästen Voraussetzung ist (wie das Schließen der Türen bei Anzeige von Lichtsignal A 2 nach BOStrab), wird nur das sicherheitsrelevante Grenzverhalten als Mindestanforderung betrachtet. Da jedoch nur die Begrenzungen des Verhaltens und somit ausschließlich Einschränkungen betrachtet werden, wird zusätzlich die Grundanforderung definiert, dass die Straßenbahn einem Fahrauftrag (inkl. Route und vorgegebenen Haltestellen) folgt. So wird auch ein intrinsisch motiviertes Losfahren bei Abwesenheit von zum Halt zwingender Einschränkungen als Anforderung berücksichtigt.

Das Grenzverhalten ist als Summe aller Einschränkungen aus folgenden Quellen abgeleitet:

- BOStrab

- Rahmen-Dienstanweisung des Verbands deutscher Verkehrsbetriebe: *Dienstanweisungen für den Fahrdienst mit Straßenbahnen*<sup>102</sup>
- Regeln des gesunden Menschenverstandes<sup>103</sup>
- Einzelfallbetrachtung aller Vorfahrtsregeln an Kreuzungsstellen mit allen Verkehrsarten innerhalb des Darmstädter Straßenbahnnetzes

Basierend auf dem identifizierten und nachfolgend aufgezeigten Grenzverhalten der Straßenbahn ist dieses in drei übergeordnete Kategorien unterteilt:

**Limitierung der Geschwindigkeit:** Für jeden Aufenthaltsort der Straßenbahn existiert eine Höchstgeschwindigkeit. Diese ergibt sich aus der gesetzlich vorgeschriebenen und somit immer vorhandenen Streckenhöchstgeschwindigkeit sowie gegebenenfalls zusätzlich restriktiveren Überlagerungen. Diese Überlagerungen können bspw. durch gesetzliche Begrenzungen wie bei Durchfahrten an Haltestellen (also unabhängig der Streckenhöchstgeschwindigkeit) oder witterungsbedingt sein. Alle Einschränkungen der Geschwindigkeit werden in dieser Kategorie mit der Kurzbezeichnung *LG* zusammengefasst.

**Einschränkung der Weiterfahrt:** Kann aufgrund weiterer Verhaltensregeln nicht mit der Geschwindigkeit, welche durch ein *LG* vorgegeben ist, gefahren werden, so gilt die Weiterfahrt als eingeschränkt. Unter dieser Kategorie mit der Kurzbezeichnung *EW* werden örtliche Einschränkungen wie der Halt an einem Lichtsignal oder einer Haltestelle zusammengefasst. Aber auch ortsfeste sowie bewegliche Hindernisse werden berücksichtigt. Die Folgefahrt bezüglich anderer Verkehrsteilnehmer und die allgemeine Kollisionsvermeidung verhindert ebenfalls eine uneingeschränkte Weiterfahrt mit Höchstgeschwindigkeit. Beide Elemente sind daher auch in dieser Kategorie als aufgezeigte Anforderung berücksichtigt.

**Weitere Aktionen:** Alle weiteren Handlungen, die als externes Verhalten beobachtet werden, gelten ebenfalls als Grenzverhaltens. Sofern diese jedoch nicht wie oben beschrieben auf den eindimensionalen Freiheitsgrad der Beschleunigung entlang der Schiene zurückzuführen sind, werden diese unter der Kategorie mit der Kurzbezeichnung *WA* zusammengefasst. Dies umfasst bspw. den erforderlichen Einsatz der Fahrtrichtungssignale oder das kurzzeitige Abschalten des Fahrstroms bei Durchfahrt unter Stromkreistrennstellen des Fahrdrahtes, die häufig auch als Streckentrenner bezeichnet werden.

Das identifizierte Verhalten ist als 21 verschiedene Anforderungen nachfolgend in Tabelle 4-1 zusammengefasst:

---

102 VDV: Dienstanweisungen für den Fahrdienst mit Straßenbahnen (2002).

103 Siehe Definition in Kapitel 2.1.

Tabelle 4-1: Funktionale Anforderungen basierend auf dem Grenzverhalten.

<b>Art</b>	<b>Verhaltensanforderung</b>	<b>Bez.</b>
<i>Limitierung Geschwindigkeit</i>	Die abschnittsweise festgelegte Streckenhöchstgeschwindigkeit darf nicht überschritten werden.	<i>LG1</i>
	Die Geschwindigkeit bei Vorbeifahrt an Haltestellen ohne Halt darf 40 km/h nicht überschreiten.	<i>LG2</i>
	Die Geschwindigkeit einer spitzbefahrenen Weiche darf 15 km/h nicht überschreiten sofern diese nicht verschlossen ist.	<i>LG3</i>
	Die Geschwindigkeit ist so anzupassen, dass der Halt an einer LSA möglich ist.	<i>LG4</i>
	Die Geschwindigkeit ist an die vorherrschenden Witterungsbedingungen und Tagesbedingungen anzupassen.	<i>LG5</i>
<i>Einschränkung Weiterfahrt</i>	Bei BÜ 0 Signal ist zu halten und nur weiterzufahren, wenn es die Verkehrslage erlaubt.	<i>EW1</i>
	Bei F0 Signal ist zu halten. Eine Vorbeifahrt darf nur im Störfall erfolgen und wenn es die Verkehrslage erlaubt.	<i>EW2</i>
	Bei F5 muss nach BOStrab entsprechend §9 StVO entgegenkommender Verkehr vor dem Abbiegen durchgelassen werden.	<i>EW3</i>
	Bei Schutzsignal Sh 1 ist vor Weiterfahrt zu halten.	<i>EW4</i>
	Bei Schutzsignal Sh 2 ist ohne anschließende Weiterfahrt zu halten.	<i>EW5</i>
	Bei Schutzsignal Sh 3 ist ein Nothalt durchzuführen.	<i>EW6</i>
	Bei zusammenlaufenden Gleisen ist nicht nach dem Grenzzeichen zu halten.	<i>EW7</i>
	An Haltestellen des Fahrauftrages ist zu halten.	<i>EW8</i>
	Vor Bereich mit Begegnungsverbot nur weiterfahren, wenn Bereich nicht bereits durch entgegenkommende Bahn belegt.	<i>EW9</i>
	Bei von Routenplanung abweichender Lage der Weiche ist zu halten.	<i>EW10</i>
	Anweisungen von Polizeibeamten nach § 36 StVO ist zu folgen.	<i>EW11</i>
Für Hindernisse ist zu halten oder langsamer zu fahren.	<i>EW12</i>	
<i>Weitere Aktion</i>	Fahrtrichtungssignal ist bei Wechsel Gleisanlage, Annäherung Fahrstreifen, Abfahrt von Haltestellen am Fahrbahnrand, lokalen Besonderheiten sowie beim Abbiegen zu betätigen.	<i>WA1</i>
	Bei Schaltsignal St 1 bzw. St 2 ist der Signal- bzw. Weichenkontakt zu betätigen.	<i>WA2</i>
	Bei Streckentrennern ist der Fahrstrom kurzzeitig abzuschalten.	<i>WA3</i>
	Bei Signal Sh 4 ist ein akustisches Warnsignal abzugeben.	<i>WA4</i>

## 4.2 Referenzarchitektur

Für den Entwurf der Referenzarchitektur werden nicht-modulare Lösungen wie vollständig Ende-zu-Ende gelernte KI-Algorithmen nicht berücksichtigt, da ihr später zu erfolgreicher Sicherheitsnachweis erheblich erschwert ist. Aus diesem Grund wird die Referenzarchitektur modular entworfen, grundsätzlich ist *Silent Testing* jedoch auch für nicht-modulare Lösungen wie Ende-zu-Ende gelernte KI-Algorithmen anwendbar, eine Zuordnung der Kausalität kann für solche Verfahren jedoch erschwert sein.

Die Ableitung der einzelnen Module erfolgt anhand der zuvor identifizierten funktionalen Verhaltensanforderungen. Dazu werden die Anforderungen *LG1–5*, *EWI–12* sowie *WAI–4* einem oder mehreren Modulen zugeordnet. Grundsätzlich sind eine Vielzahl an verschiedenen Architekturen möglich. Dies zeigt sich bereits bei den verfügbaren Informationsquellen. Die Referenzarchitektur wird daher in einem ersten Schritt als verallgemeinerte Architektur unter Berücksichtigung allgemeingültiger nachfolgend aufgezeigter Motivatoren (wie dem Nutzen einer Karte) entworfen. Anschließend wird diese allgemeingültige Referenzarchitektur mit zusätzlichen Vorgaben in eine lösungsorientierte Architektur überführt und als Referenzimplementierung umgesetzt.

Im Bereich der Vollbahnen und bereits automatisierter Metros fokussieren sich Architekturen des automatisierten Fahrens vornehmlich auf die Umsetzung der Automatisierung im Rahmen der Zugsicherung und den damit verbundenen Systemen zu ATO.<sup>104, 105, 106, 107</sup> Insbesondere für die Vollbahn wird innerhalb von ATO auch die Streckenbeobachtung in Form einer Perzeption von Hindernissen berücksichtigt. Diese konzentriert sich jedoch aufgrund der Reservierung der Gleise für den Bahnverkehr vornehmlich auf kritische Hinderniserkennung mit Notmanövern. Aufgrund der zentralisierten Sicherheitsphilosophie sind die Architekturen der Vollbahn und automatisierten Metros nicht auf das *Fahren auf Sicht* und der damit erforderlichen Erfassung der Umgebung (Infrastruktur wie auch Objekte) sowie der dezentralen Entscheidungsfindung von Straßenbahnen übertragbar.

Innerhalb der Architekturen von Kraftfahrzeugen werden üblicherweise die übergeordneten englischsprachigen Architekturgruppen für Robotik Agenten *Sense-Plan-Act* sowie Derivate davon wie *Sense-Model-Plan-Act* als erste Abstraktionsebene verwendet.<sup>108, 109</sup> Für die Referenzarchitektur wird daher die gleiche Unterteilung entsprechend Abb. 4-2 unternommen und die Bereiche unter Zuhilfenahme verschiedener Annahmen und Analysen in einzelne Module definiert.

---

104 Wang, Z. et al.: Assessment of architectures for ATO (2022).

105 Gerd Tasler; Volker Knollmann: Einführung des hochautomatisierten Fahrens (2018), S. 10.

106 Ďuračák, M. et al.: Software architecture of Automatic Train Operation (2019).

107 Peleska, J. et al.: Standardisation Considerations for Autonomous Train Control (2022), S. 7.

108 Tas, O. S. et al.: Functional system architectures (2016), S. 305.

109 Kortenkamp, D. et al.: Robotic Systems Architectures and Programming (2016), S. 285.



Abbildung 4-2: Übergruppen Sense-Plan-Act der Referenzarchitektur.

## 4.2.1 Architekturgruppe Sense

Die Erfassung sämtlicher erforderlicher Information für die Erfüllung der in Tabelle 4-1 gelisteten Verhaltensanforderungen sind in dieser Architekturgruppe zusammengefasst.

**Sensorische Erfassung:** Da das System entsprechend der Verhaltensanforderung *EW12* umgebende Objekte und so unmittelbare oder zukünftige Hindernisse wie ein menschlicher Fahrer wahrnehmen muss, wird wie bei automatisierten Kraftfahrzeugen auch eine Umfeldsensorik benötigt. Dabei wird angenommen, dass aufgrund des Blickwinkels der Sensoren und der spezifischen Vor- sowie Nachteile bzw. Eigenschaften verschiedener Sensortechnologien mehrere Umfeldsensoren eingesetzt werden. Die verschiedenen Sensoren sind als Eingangsdaten für einen Planungsalgorithmus zu einer virtuellen Repräsentation des Objektumfeldes zu fusionieren. Je nach Konkretisierung der allgemeinen Referenzarchitektur ist die Umfeldsensorik zusätzlich Eingangsquelle für die verschiedenen nachfolgend genannten Module der *Sense* Gruppe. Neben Sensorik, die das Umfeld erfasst, ist auch die sensorische Erfassung des Ego-Zustandes der Straßenbahn als weitere Berechnungsgrundlage für das Sollverhalten in dieser Architekturgruppe abgebildet.

**Digitale Karte:**<sup>110</sup> Rasmussen unterteilt die menschliche kognitive Leistung während einer zielgerichteten Tätigkeit als Kombination aus *wissensbasiertem*, *regelbasiertem* und *fähigkeitsbasiertem* Verhalten.<sup>111</sup> Donges verknüpft diese drei Verhaltensebenen wiederum mit drei definierten Fahraufgaben *Navigation*, *Führung* sowie *Stabilisierung*.<sup>112</sup> Zu dem wissensbasierten Verhalten, welches in die Fahraufgaben *Navigation*, und *Führung* fließt, lässt sich auch das Wissen zu örtlichen Gegebenheiten eingliedern. Digitale Karten für das automatisierte Fahren im Automobilssektor werden als ein Schlüsselaspekt betrachtet. Vergleichbar ist das mit einem Menschen mit Ortskenntnissen, dem auf Grundlage seines Wissens die Fahraufgabe erleichtert wird. Im Gegensatz zu normalen Karten werden solche im Anwendungsbereich der Automatisierung nicht nur zur Routenplanung und Navigation verwendet. Diese bieten auch Metainformationen wie Geschwindigkeitsbegrenzungen sowie anspruchsvolle geodätische Informationen über die Umgebung wie die Position

110 Einzelne Teile dieses Abschnittes wurden bereits veröffentlicht in: Ruppert, T. et al.: Map-Based Path and Pose for Trams (2021) © 2021 IEEE.

111 Rasmussen, J.: Skills, rules, and knowledge (1983).

112 Winner, H. et al.: Handbuch Fahrerassistenzsysteme (2015), S. 18–19.

von Fahrbahnbegrenzungen oder Landmarken zur Lokalisierung.<sup>113</sup> Für Straßenbahnen ergeben sich gegenüber Kraftfahrzeugen nochmals stärkere Motivatoren eine digitale Karte zur Automatisierung zu verwenden:

- Das Einsatzgebiet von Straßenbahnen weist eine geringere räumliche Ausdehnung auf als das von Kraftfahrzeugen oder Fernverkehrszügen. Dieser kleinere Betriebsbereich führt zu einer gleichzeitigen Verringerung der Informationsvariationen, die in der Karte hinterlegt werden müssen. Die Anzahl an Ausnahmen innerhalb eines Betriebsbereiches reduziert sich, während auftretende Ausnahmen einfacher in die Karte integriert werden können, da weder die Karte noch das zugrundeliegende Datenschema eine ausnahmslose Allgemeingültigkeit für alle Betriebsbereiche weltweit aufweisen muss.
- Änderungen an der Infrastruktur (Neue LSA, Änderungen von Gleisverläufe etc.) sind dem Betreiber im Vorfeld bekannt und liegen teilweise sogar in seiner Planungsverantwortung. Dies ermöglicht stets eine Aktualisierung der Karte zum Zeitpunkt der Änderung. Den Kartendaten kann daher im Rahmen der Automatisierung ein größeres Maß an Vertrauen zugesprochen werden.
- Aufgrund der Spurbindung der Straßenbahn reduziert sich der Freiheitsgrad auf eine eindimensionale Bewegung entlang der Schiene. Die Position der Straßenbahn ist somit in hohem Maße reproduzierbar, womit eine nochmals detailliertere und robustere Karte ermöglicht wird. Bspw. könnten in der Karte Regions of Interest (ROI) von LSA für eine kamerabasierte Erfassung der Signale hinterlegt werden.
- Durch die Spurbindung und im Vergleich zu Kraftfahrzeugen genauer reproduzierbare Position, kann der Gleisverlauf als Bahnkoordinate und somit als Referenz für Information dienen.

Basierend auf diesen Motivatoren wird eine digitale Karte als Wissensbasis in der hier vorgeschlagenen Referenzarchitektur festgelegt. Zur Nutzung der Karte ist zusätzlich auch ein Modul zur Lokalisierung der Bahn erforderlich.

**Kenntnis Streckenhöchstgeschwindigkeit:** Zur oberen Begrenzung der Höchstgeschwindigkeit ist Kenntnis über die abschnittsweise gültige Streckenhöchstgeschwindigkeit *LG1* erforderlich.

**Zustandserfassung LSA:** Für die Erfüllung der Verhaltensanforderungen *EW1*, *EW2*, *EW3*, *EW6*, *EW10* sowie *LG4* für Schutzsignal Sh 3 d nach BOStrab ist das angezeigte Signal von LSA aller Arten (Vorfahrt, Bahnübergänge (BÜ), Weichen) zu erfassen. Da wie in den Prämissen aufgeführt die Automatisierung für Straßenbahnen, die *auf Sicht fahren*,

---

113 Liu, R. et al.: High Definition Map for Automated Driving (2020).

betrachtet wird und üblicherweise nicht alle LSA eines Straßenbahnnetzes in eine Zugsicherung eingebunden sind, ist die optische Perzeption des Signals mit einer oder mehreren Kameras erforderlich. Zur Erfüllung des Grenzverhaltens wäre nur die Erfassung des halt zeigenden Signals erforderlich. An dieser Stelle wird jedoch angenommen, dass aufgrund der Erfassung mit Kameras und damit verbundener Unsicherheiten auch ausgeschaltete sowie fahrt zeigende Signale zu erfassen sind. Da an Weichen mehrere LSA vorhanden sein können, ist zusätzlich die Kenntnis über die Zuordnung der erfassten Lichtsignale zu den verzweigenden Fahrwegen erforderlich.

**Kenntnis Haltestellen:** Zum Halt *EW8* sowie zur Anpassung der Geschwindigkeit bei Durchfahrt an Haltestellen *LG2* ist die Kenntnis über das Vorhandensein und den Ort der Haltestellen erforderlich.

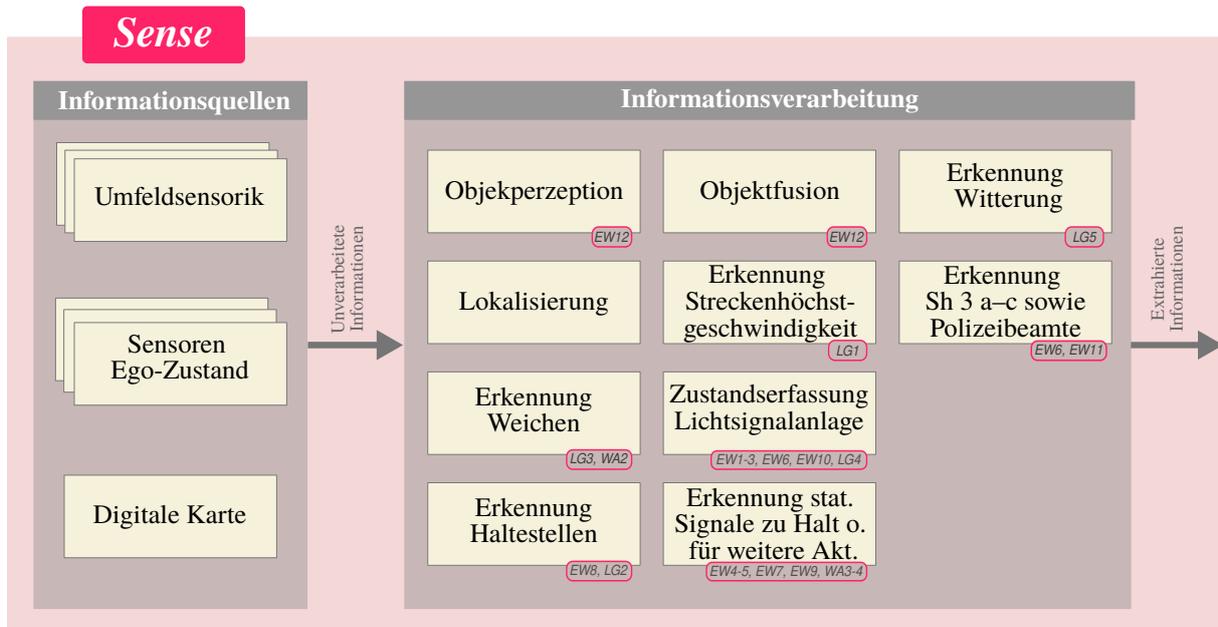
**Kenntnis Weichen:** Zur erforderlichen Begrenzung der Geschwindigkeit an nicht verschlossenen, spitzbefahrenen Weichen *LG3* sowie zur Betätigung des Weichenkontaktes zum Stellen der Weiche *WA2* ist die Kenntnis über das Vorhandensein und den Ort der Weichen sowie der gegen die Fahrtrichtung davor liegenden zugehörigen Schaltkontakte erforderlich.

**Erkennung statischer Signale zu Halt oder Aktion:** Signale, die nicht über eine LSA oder einen Menschen angezeigt werden, sind als statische Signale zusammengefasst. Zur Erfüllung der Verhaltensanforderungen *EW4*, *EW5*, *EW7*, *EW9* sowie *WA3* und *WA4* ist die Kenntnis über das Vorhandensein und den Ort der Schutzsignale *Sh 1–2* zum Halt, *Sh 4* zur Abgabe eines akustischen Warnsignals, von Grenzzeichen damit nicht nach diesen gehalten wird, von Begegnungsverboten sowie von Streckentrennern erforderlich.

**Erkennung *Sh 3 a–c* sowie Verkehrsregelung Polizeibeamte:** Ein extern bestimmter erforderlicher Nothalt ist dem Fahrer nach BOStrab mit einem der vier verschiedenen Schutzsignale *Sh 3 a–d* anzuzeigen. Das Signal *Sh 3 a* ist ein akustisches Zeichen und muss wie die Handzeichen mit Laterne oder Fahne von Zugehörigen des Betriebes nach *Sh 3 b–c* mithilfe der Umfeldsensorik erkannt werden. *Sh 3 d* ist als LSA ausgeführt und somit bereits in **Zustandserfassung LSA** berücksichtigt. Ähnlich wie die vom Menschen angezeigten Schutzsignale muss auch eine Verkehrsregelung durch einen Polizeibeamten mit Umfeldsensorik erkannt werden, um *EW6* bzw. *EW11* zu erfüllen.

**Kenntnis Witterung:** Für die Begrenzung der Geschwindigkeit nach *LG5* sind die vorherrschenden Witterungsbedingungen wahrzunehmen.

In Abb. 4-3 sind die oben beschriebenen Module mit der Zuweisung zu den Verhaltensanforderungen für die Architekturgruppe *Sense* zusammengefasst.

Abbildung 4-3: Referenzarchitektur *Sense*.

## 4.2.2 Architekturgruppe *Plan*

Nach der Erfassung von relevanten sowie unumgänglich auch nicht relevanten Informationen in *Sense* sind diese in *Plan* nach Relevanz zu filtern, zu bewerten und ein Sollverhalten daraus abzuleiten. Innerhalb der Architekturgruppe sind alle Verhalten nach Tabelle 4-1 zu berücksichtigen und gegeneinander abzuwägen, d. h. aus mehreren Verhaltensquellen gilt es ein einziges Sollverhalten auszuwählen, welches zur Umsetzung an *Act* übermittelt wird. Verhaltensanforderungen werden ähnlich wie zuvor in *Sense* gruppiert und ein zugehöriges Modul definiert. Das geplante Sollverhalten besteht aus der Beeinflussung der Geschwindigkeit entlang der Schiene (bspw. eine Sollbeschleunigung) sowie weiteren Aktionen (bspw. das Betätigen des Fahrtrichtungssignals).

**Berücksichtigung von Hindernissen:** Sensorisch erfasste Objekte des Umfeldes sind zu prüfen, ob diese als relevante Hindernisse klassifiziert und entsprechend der Anforderung *EW12* im Verhalten zu berücksichtigen sind. Darunter fällt einerseits der Halt (ggf. mit einer Gefahrenbremsung), andererseits aber auch die Folgefahrt im fließenden Verkehr sowie die Reduzierung der Geschwindigkeit, um bereits kreuzende Verkehrsteilnehmer nicht zu gefährden. Darüber hinaus muss im Fall eines erkannten Lichtsignals F 5 nach *EW3* vor dem Abbiegen entgegenkommenden Verkehrsteilnehmern die Vorfahrt gewährt werden.

**Auswahl und Regelung Höchstgeschwindigkeit:** Aus den sensorisch und gegebenenfalls als Karte hinterlegten Informationen (Konkretisierung im Rahmen der lösungsorientierten Architektur) ist die für die Position der Bahn abschnittsweise gültige Höchstgeschwindigkeit für *LG1–LG5* zu bestimmen. Neben der Wahl der Höchstgeschwindigkeit ist auch die Regelung auf dieses Regelziel in diesem Modul zu berücksichtigen.

**Halt an vorfahrtsregelnden LSA:** Die sensorisch erfassten Signale der LSA sind hinsichtlich ihrer Relevanz (Gültigkeit für den eigenen Fahrweg an Weichen etc.) zu bewerten. Für die uneingeschränkte Weiterfahrt nach *EW1*, *EW2*, *EW6* ist die Abwesenheit Halt zeigender Signale zu berücksichtigen, andernfalls ist als Sollverhalten auf ein Halt vor dem Lichtsignal zu regeln. Bei der Wahl des Haltepunktes sind Halteverbote durch Grenzzeichen nach *EW7* zu berücksichtigen.

**Halt an Haltestellen:** Zur Erfüllung des Beförderungsauftrages ist an erkannten Haltestellen entsprechend der Anforderung *EW8* auf ein Halt an der Haltelinie zu regeln und nach dem Fahrgastwechsel der Halt für eine uneingeschränkte Weiterfahrt zu beenden.

**Stellanforderung und Halt an Weichen:** Basierend auf der Route aus dem a-priori bekannten Fahrauftrag ist im Bereich des Weichen- bzw. Signalkontaktes die Betätigung des Kontaktes zur Erfüllung von *WA2* als Aktion durchzuführen und die korrekte Lage von Weichen zur Erfüllung von *EW10* zu prüfen und bei Abweichung auf ein Halt vor der Weiche zu regeln. Bei der Wahl des Haltepunktes sind Halteverbote durch Grenzzeichen nach *EW7* zu berücksichtigen.

**Halt für statische und menschliche Signale:** Für erkannte Schutzsignale *Sh 1* bzw. *Sh 2* nach *EW4* bzw. *EW5* sowie menschlich angezeigte Signale nach *EW6* und *EW11* ist auf ein Halt vor dem Signal zu regeln.

**Warnsignal abgeben:** Für erkannte Schutzsignale *Sh 4* nach *WA4* ist ein akustisches Warnsignal abzugeben.

**Halt bei Begegnungsverbot:** Vor dem Bereich des Begegnungsverbots ist entsprechend der Anforderung *EW9* auf ein Halt zu regeln, sofern eine entgegenkommende Straßenbahn erkannt wurde.

**Abschalten Fahrstrom:** Bei erkannten Streckentrennern ist der Fahrstrom entsprechend der Anforderung *WA3* kurzzeitig abzuschalten, um unnötigen Verschleiß oder Beschädigungen an Fahrdrabt und Stromabnehmer durch induktiv erzeugte Lichtbögen zu vermeiden. Dies bezieht sich auch auf das Bremsen, da Straßenbahnen normalerweise Energie rekuperieren und diese in das Stromnetz zurückspeisen. Sollte jedoch abhängig vom vorherrschenden Szenario eine unerwartet starke Bremsungen erforderlich sein, ist die Abschaltung abzuwägen. Zwar gilt für die stärkste Bremsung — die sogenannte Gefahrenbremsung —, dass die Energie nicht rekuperiert, sondern über elektrische Widerstände dissipiert wird, aufgrund der Sturzgefahr der Fahrgäste kann jedoch bewusst eine geringere —üblicherweise rekuperierende — Bremsung gewählt werden.

**Auswahl des Verhaltens:** Die verschiedenen Module bestimmen bei Aktivität jeweils ein eigenes Sollverhalten. Je nach Szenario kommt es zur Überlagerung dieser bestimmten Sollverhalten. So ist bspw. der Halt für ein Lichtsignal erforderlich während gleichzeitig

noch davor ein Hindernis erkannt wurde. In diesem Fall ist das Sollverhalten des Hindernisses höher zu gewichten. Die Auswahl des Sollverhaltens ist in diesem Modul zu bestimmen.

**Betätigung Fahrtrichtungssignal:** Je nach ausgewähltem Verhalten ist das Fahrtrichtungssignal entsprechend der Anforderung *WA1* zu betätigen.

In Abb. 4-4 sind die oben beschriebenen Module mit der Zuweisung zu den Verhaltensanforderungen für die Architekturgruppe *Plan* zusammengefasst.

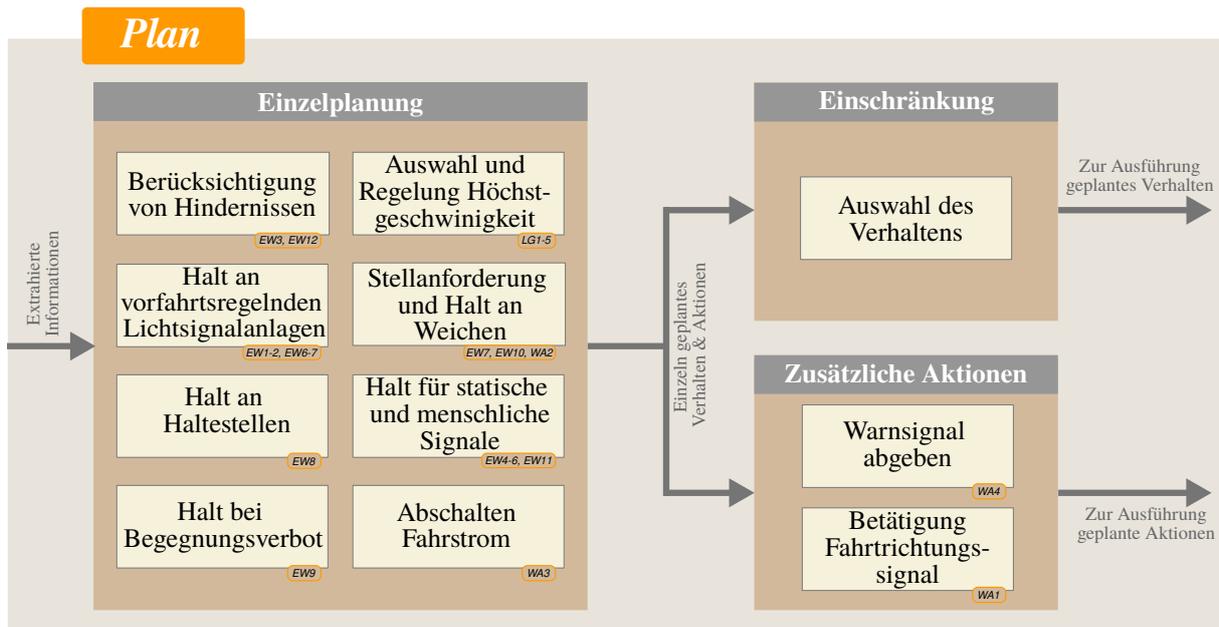


Abbildung 4-4: Referenzarchitektur *Plan*.

### 4.2.3 Architekturgruppe *Act*

Das in der Gruppe *Plan* bestimmte Verhalten ist fahrzeugspezifisch umzusetzen. Im Gegensatz zu Kraftfahrzeugen muss hierbei jedoch nicht die Trajektorie des Fahrzeuges eingehalten, sondern aufgrund der Spurführung die Regelung des eindimensionalen Freiheitsgrads entlang der Schiene erfolgen. Die Umsetzung hängt jedoch insbesondere von der restlichen Fahrzeugarchitektur, den verfügbaren Schnittstellen sowie Aktoren der jeweiligen Straßenbahn ab. Neben der Umsetzung der geplanten Beeinflussung entlang der Schiene ist auch die Umsetzung *weiterer Aktionen* wie das Betätigen des Fahrtrichtungssignals zu berücksichtigen.

**Stabilisierung des Fahrzeuges:** Die Sollwertvorgabe zum Fahren oder Bremsen als Ausgabe der Verhaltensplanung ist unter Berücksichtigung der Eigendynamik des Fahrzeuges und der Witterungsbedingungen zu regeln. Die Stellgrößen sind entsprechend der spezifischen Umsetzung des Fahrzeuges durch Aktoren sowie diesen zugehörigen untergeordneten Regelkreisen umzusetzen.

**Umsetzung weiterer Aktionen:** Von der Verhaltensplanung bestimmte WA wie das Betätigen des Weichenkontaktes oder der Fahrtrichtungssignale sind entsprechend der spezifischen Schnittstellen der Straßenbahn umzusetzen.

In Abb. 4-5 sind die abstrakten Module der Architekturgruppe *Act* zusammengefasst. Die konkrete Umsetzung der Module und untergelagerte Regelschleifen sind abhängig von der spezifischen Fahrzeugarchitektur.



Abbildung 4-5: Referenzarchitektur *Act*.

Mit den abgeleiteten Verhaltensanforderungen ist FF. 4 zum Umfang der Automatisierung der Straßenbahn erstmalig beantwortet. Dabei ist jedoch zu beachten, dass die in diesem Kapitel abgeleiteten Anforderungen nur auf einer theoretischen Betrachtung beruhen und insbesondere mit der Anwendung von *Silent Testing* in Kapitel 5 sich weitere Anforderungen aus der Praxis ergeben können. Dennoch ist auf den theoretisch identifizierten Verhaltensanforderungen im Rahmen der getroffenen Prämissen eine allgemeingültige Referenzarchitektur entworfen, welche für verschiedene Umsetzungen konkretisiert werden kann.

### 4.3 Konkretisierung der Referenzarchitektur

Zur Anwendung der allgemeingültigen Referenzarchitektur werden nachfolgend weitere Einschränkungen getroffen und Lösungskonzepte ausgewählt, um eine konkretisierte Architektur abzuleiten. Diese ist Basis für die nachfolgende Referenzimplementierung als OuT zur Anwendung von *Silent Testing*.

Allen nachfolgend getroffenen Einschränkungen und Auswahlen liegt zugrunde, dass die Komplexität des Gesamtsystems zunächst möglichst gering gehalten werden soll. Sollten vergleichsweise einfachere Algorithmen bereits zur Automatisierung ausreichen, so sind diese zu bevorzugen, um mutmaßlich auch die Umsetzung und anschließende Validierung im Rahmen eines Produktivsystems zu vereinfachen. Diese a-priori getroffenen Entscheidungen werden durch die Anwendung von *Silent Testing* in Kapitel 5 auf ihre Unzulänglichkeit überprüft. Nachfolgend werden die Einschränkungen des Lösungsraums durch eine Konzeptauswahl durchgeführt. Die detaillierte

Beschreibung der jeweiligen technischen Umsetzung erfolgt im Rahmen der Implementierung in Kapitel 4.4.

### 4.3.1 Nicht betrachtete Verhaltensanforderungen

Im Rahmen dieser Arbeit werden nachfolgende Verhaltensanforderungen aus den genannten Gründen nicht weiter betrachtet:

- Aufgrund des seltenen Auftretens und dem erforderlichen Mikrofon zur Erfassung, wird das extern gegebene akustische Signal Sh 3 a, welches nach BOStrab einen Nothalt auffordert, nicht betrachtet. Ebenfalls aufgrund der im Betrieb mit Fahrgästen üblicherweise nicht vorkommenden Signale Sh 3 b–c, welche einen Nothalt durch Zugehörige des Betriebes anordnen, werden nicht weiter berücksichtigt. Da es in Darmstadt keine LSA zum Schutzhalt mit Sh 3 gibt, entfällt *EW6* im Rahmen der Referenzimplementierung vollständig.
- Ebenfalls aufgrund des seltenen Auftretens und des mit der Umsetzung verbundenen Aufwandes wird die Erkennung von Anweisungen von Polizeibeamten nach *EW11* nicht betrachtet. Für den Realbetrieb ist die Erkennung der Anweisungen von Polizeibeamten oder Rückfallebenen wie die Teleoperation, also die Fernsteuerung aus einer Leitzentrale heraus, jedoch erforderlich.
- LSA, welche die Lage und den Zustand der Verriegelung von Weichen anzeigen, werden im Rahmen der Referenzimplementierung nicht berücksichtigt. Für das Training maschinell gelernter Verfahren sind dem Autor keine öffentlich verfügbaren annotierten Datensätze mit den Weichensignalen W 1–3 und W 11–14 nach BOStrab bekannt. Die Erstellung von annotierten Datensätzen ist aufwendig und erfolgt im Rahmen dieser Arbeit bereits für die Erkennung vorfahrtsregelnder LSA. Es wird davon ausgegangen, dass die im Rahmen von *Silent Testing* identifizierten Herausforderungen für die Erkennung von vorfahrtsregelnden LSA auch für die Erkennung von Weichensignalen gelten. Die Überprüfung der Weichenlage nach *EW10* ist somit nicht Teil dieser Arbeit.
- Wie in Kapitel 3.3.2 definiert, wird im Rahmen dieser Arbeit das Verhalten von Automatisierung und Fahrer nur anhand  $|\Delta a|$  auf Abweichungen überprüft. Daher werden *WA1*, *WA3–WA4* also Betätigungen der Fahrtrichtungssignale, Weichenkontakte oder akustische Warnsignale nicht betrachtet. Für diese Verhaltensanforderung werden jedoch aufgrund der einfachen Umsetzbarkeit für ein Produktivsystem keine straßenbahnspezifischen Herausforderungen im Sinne der genannten Motivation zur Anwendung von *Silent Testing* erwartet.
- Die Bestimmung des Fahrauftrages im Sinne des oben genannten intrinsisch motivierten Losfahrens wird nicht berücksichtigt. Es wird davon ausgegangen, dass Route sowie Haltestellen als Fahrauftrag vorgegeben sind.

- Da sich diese Arbeit nur mit den Herausforderungen der Fahraufgabe beschäftigt und der Halt an Haltestellen mit *EW8* als Teil der Fahraufgabe berücksichtigt wird, wird die Freigabe der Türen sowie deren Widerrufung als Teil des Fahrgastwechsels nicht näher betrachtet.
- Die Architekturgruppe *Act* wird nicht weiter berücksichtigt, da keine reale automatisierte Fahrt mit der Versuchsbahn durchgeführt werden soll, sondern im Rahmen von *Silent Testing* das geplante Verhalten als Ausgang von *Plan* bereits ausreicht.

### 4.3.2 Objektdetektion

#### Fusion

Die zur praktischen Untersuchung eingesetzte und in Kapitel 3.3.4 beschriebene Forschungsbahn des Projektes MAAS ist mit Radar- und Lidarsensoren sowie Kameras zur Detektion von Objekten im Umfeld der Straßenbahn ausgestattet. Die verschiedenen Sensortechnologien finden im Kraftfahrzeugbereich einzeln oder in Kombination in verschiedenen Forschungs- wie Serienfahrzeugen Anwendung. Zur Zusammenführung der unterschiedlichen Sensordaten wird üblicherweise in drei Abstraktionsebenen der Fusion unterschieden:<sup>114</sup>

- *High-Level*: Die Fusion erfolgt auf Basis von Objekten, die von den Sensoren jeweils einzeln detektiert und als Objektlisten an das Fusionsmodul übergeben werden. Der Vorteil besteht in der Unabhängigkeit der einzelnen Sensoren und verglichen mit den anderen Methoden reduzierten Komplexität.
- *Low-Level*: Die Fusion erfolgt auf den unmittelbaren Rohdaten der Sensoren. Rohdaten können jedoch je nach Ausgabe vom Sensor und Betrachtung unterschiedlich aufgefasst werden, meinen zu meist jedoch Detektionen wie bspw. Punktwolken bei Lidar. Der Vorteil besteht darin, dass durch das niedrige Level an Abstraktion noch keine Information verloren gegangen ist und das detektierte Objekt eine höhere Genauigkeit aufweist. Der Nachteil besteht in der höheren Komplexität und der Abhängigkeit der Sensoren untereinander.
- *Mid-Level*: Die Fusion erfolgt auf Merkmalen, die aus jedem Sensor getrennt extrahiert werden. Die Merkmale beinhalten dabei noch mehr Informationen als bereits einzeln identifizierte Objekte, spannen jedoch kleinere Informationsräume als die *Low-Level*-Fusion auf und verbrauchen dabei weniger Rechenleistung. Üblicherweise werden diese Ansätze maschinell gelernt ausgeführt.

Da die Eignung der verschiedenen Sensortechnologien im Kontext der Straßenbahn in der Literatur noch nicht bewertet ist, es im Gegensatz zum Kraftfahrzeugbereich keine öffentlichen annotierten Datensätze zur Nutzung maschinell gelernter Verfahren gibt sowie die Komplexität

---

114 Yeong, D. J. et al.: Sensor and Sensor Fusion Technology in Autonomous Vehicles (2021), S. 27.

zunächst gering gehalten werden soll, wird die Fusion der Referenzimplementierung auf Basis des *High-Level*-Ansatzes entworfen. Daher ist für jeden Sensor ein Modul zur Detektion von Objekten im Umfeld der Straßenbahn erforderlich.

## **Radar**

Werkseitig verfügen die eingesetzten Radare bereits über einen vom Hersteller für die Anwendung im Kraftfahrzeug entwickelten Algorithmus zur Erkennung von Objekten des Straßenverkehrs. Die vom Sensor bereitgestellte Objektliste beschreibt im wesentlichen Position, Größe und Orientierung einer starren rechteckigen Boundingbox sowie die aus dem Dopplereffekt bestimmte Geschwindigkeit detektierter Objekte. Die räumlichen Informationen sind aufgrund einer fehlenden Höhenmessung auf die horizontale Ebene beschränkt und somit nur 2D. Da kein Zugriff auf weitere Vorverarbeitungsstufen wie Detektionen der Radare besteht, werden die vom Radar erzeugten Objekte als gegeben angenommen.

## **Lidar**

Die beiden Lidarsensoren — auf dem Dach und in der Frontschürze der Straßenbahn — geben dreidimensionale Punktwolken als Rohdaten der erfassten Umgebung aus. Die zu detektierenden Objekte sind vom Hintergrund (Gebäude, Boden etc.) zu trennen und als Objekte zu identifizieren. Im Kraftfahrzeugbereich werden dazu üblicherweise Clustering-Methoden oder maschinell gelernte Verfahren eingesetzt. Clustering basiert auf verschiedenen analytischen Verfahren bei denen Punkte basierend auf Merkmalen zur Ähnlichkeit wie bspw. der euklidischen Distanz zu Objekten zusammengefasst werden. Maschinell gelernte Verfahren basieren üblicherweise auf einem annotierten Datensatz, mit dessen Hilfe der Detektor trainiert wird. Darüber hinaus existieren in vergleichsweise geringer Anzahl neuartige Ansätze für unüberwachtes Lernen ohne einen erforderlichen annotierten Datensatz<sup>115</sup>. Für den im Kraftfahrzeugbereich bekannten KITTI-Datensatz<sup>116</sup> existiert ein öffentlicher Vergleich verschiedener Detektoren<sup>117</sup>. Die oberen Platzierungen basieren alle auf verschiedenen Methoden des überwachten Lernens. Aufgrund unterschiedlicher Auflösungen und Sensorpositionen sowie weiteren immanenten Eigenschaften wie Reichweite, Rauschverhalten etc. ist der sogenannte Domänentransfer bei Lidar erschwert.<sup>118</sup> Maschinell gelernte Detektoren funktionieren nicht oder nur eingeschränkt, wenn sie in Umgebungen oder für Sensoren eingesetzt werden, die nicht dem zugrunde liegenden Trainingsdatensatz entsprechen.

Für Straßenbahnen existiert kein annotierter Lidardatensatz. Weiterhin ist der Transfer vom Pkw auf die Straßenbahn im Vergleich zu dem nur begrenzt möglichen Pkw-zu-Pkw Domänentransfer nochmals erheblich erschwert. Dies ist insbesondere an der unterschiedlichen Umgebung

---

115 Zhang, L. et al.: Towards Unsupervised Object Detection from LiDAR Point Clouds (2023).

116 Geiger, A. et al.: Vision meets robotics: The KITTI dataset (2013).

117 Geiger, A. et al.: Benchmark 3D Object (2023).

118 Triess, L. T. et al.: A Survey on Deep Domain Adaptation for LiDAR Perception (2021), S. 352.

wie offene Gleise, Fußgängerzonen etc. aber auch zusätzlichen Einflussfaktoren wie die Verbauposition der Sensoren im Vergleich zum Pkw-Bereich begründet. Vor allem aufgrund der unterschiedlichen Verbauhöhen werden die umgebenden Objekte von einer anderen Perspektive erfasst und sehen somit in den Daten der Straßenbahn anders als in Pkw-Datensätzen aus. Für Mustererkennungsalgorithmen, wie maschinelles Lernen, stellt dieses unterschiedliche Aussehen eine Herausforderung dar. Da weiterhin analytische Clustering-Verfahren eine geringere Komplexität bezüglich eines später zu erfolgenden Sicherheitsnachweis aufweisen, wird die Detektion von Objekten innerhalb des erarbeiteten OuT mittels eines solchen konventionellen Verfahrens umgesetzt.

## Kamera

Kameras werden zur Objektdetektion in Kraftfahrzeugen auf verschiedene Weisen wie bspw. Stereotriangulation, semantische Segmentation, 2D Objektdetektion, maschinell gelernte 3D Rekonstruktion oder als Teil der *Low-* bzw. *Mid-Level-Fusion* insbesondere zur Anreicherung der Eingangsdaten von Lidardetektoren verwendet.<sup>119, 120, 121</sup> Bereits für diese Auswahl an Verfahren existiert eine Vielzahl an unterschiedlichen Ausprägungsstufen und Kombinationen. Aufgrund der aktiv unterschiedlich genutzten Auswertemethoden gibt es keine allgemeingültige Empfehlung zur Objektdetektion bzw. Bestimmung von Hindernissen in Kamerabildern. Für die hier gewählte *High-Level-Fusion* entfällt die Anreicherung anderer Sensordaten. Für eine erste einfache Umsetzung werden die fünf Kameras der Versuchsbahn daher zur Objektdetektionen ausschließlich als Klassifikator in Form eines 2D Detektors verwendet. Ein solcher 2D Detektor erkennt die Anwesenheit sowie die Klasse eines Objektes und markiert den entsprechenden Bildbereich als 2D Boundingbox in Pixelkoordinaten.

Die Klassifikation in verschiedene Arten der Verkehrsteilnehmer ist insbesondere für die Verhaltensvorhersage und Kritikqualitätsbewertung als Teil des Planungsalgorithmus vorteilhaft: Bewegungen anderer Verkehrsteilnehmer werden basierend auf ihrer Klasse besser geschätzt, womit z. B. eine als solche erkannte Straßenbahn auf dem Gegengleis aufgrund ihrer Spurbindung kein Hindernis ist. Traditionell analytisch entworfene Methoden der maschinellen Bildauswertung weisen aufgrund der Variation der Objekte in Größe, Form, Farbe etc. sowie der Variation der Umgebungsbedingungen wie Beleuchtung, Witterung etc. eine deutlich geringere Detektionsgüte als Verfahren des tiefen maschinellen Lernens auf.<sup>122, 123</sup> Aus diesem Grund wird die Objektdetektion in Kamerabildern im Rahmen der Referenzimplementierung dieser Arbeit mittels eines maschinell gelernten Verfahrens umgesetzt. Für den potenziellen späteren

---

119 Marti, E. et al.: Review of Sensor Technologies for Perception (2019), S. 69–97.

120 Ma, X. et al.: Monocular 3D Object Detection (2019).

121 Häne, C. et al.: 3D perception using a multi-camera system (2017).

122 Xiao, Y. et al.: A review of object detection based on deep learning (2020), S. 23730–23731.

123 Zhao, Z.-Q. et al.: Object Detection With Deep Learning (2019), S. 3212–3213.

Sicherheitsnachweis eines möglichen Produktivsystems ergibt sich der Vorteil, dass eine Klassifikation der Objekte für den Planungsalgorithmus zwar vorteilhaft, jedoch nicht zwangsläufig erforderlich ist, um zum Beispiel ein Hindernis mit Lidar zu detektieren.

### 4.3.3 Zustandserfassung Lichtsignalanlagen

Da die LSA von Straßenbahnen zumeist nicht in eine Zugsicherung eingebunden sind und Änderungen an der Infrastruktur zu vermeiden sind, gilt es, wie im Rahmen der Referenzarchitektur bereits beschrieben, die angezeigten Signalzustände mittels Kamera zu erfassen. Basierend auf der gleichen Motivation zur Erkennungsleistung wie bei der kamerabasierten Objektdetektionen, wird auch die Erkennung der Signalzustände mittels maschinell gelernter Verfahren umgesetzt.

Zur Steigerung der Detektionsleistung (nachfolgend im Rahmen der Implementierung erläutert) sowie zur Schaffung der Möglichkeit im Rahmen der Verhaltensplanung auf LSA zu reagieren, die nicht mit der Kamera detektiert worden sind, erfolgt eine kartenbasierte Anwesenheitserkennung der LSA. Die Information und Modellierung hierzu wird im Rahmen der Referenzimplementierung als Teil der digitalen Karte umgesetzt.

### 4.3.4 Verwendung der digitalen Karte

Als Basis für die digitale Karte wird der Gleisverlauf gewählt. Dieser verbessert die Lokalisierung (siehe nachfolgender Abschnitt) und bildet die Grundlage für einen Diskriminator von Objekten der Umgebung als unmittelbare oder zukünftige Hindernisse als Teil des Planungsalgorithmus. Darüber hinaus bildet der Gleisverlauf implizit die Position von Weichen zur Erfüllung von WA2 und LG3 ab.

Basierend auf den im Kapitel 4.2 zur Nutzung einer digitalen Karte genannten Motivatoren werden sämtliche statischen Informationen, die derzeit im Betrieb mit menschlichem Fahrer über Verkehrszeichen oder Markierungen angezeigt werden, in der Karte hinterlegt. Im Fall von Baustellen oder temporären Änderungen sind solche grundsätzlich als Überlagerung in Form einer aus der Ferne aktualisierbaren Karte abbildbar. Die Pflege der Karte wäre folglich eine neue Aufgabe für die Leit- oder Dispositionsstelle. Die Verlagerung der Informationsquelle in eine Karte reduziert insbesondere die nachfolgenden Elemente auf eine vereinfachte Lokalisierung und Abruf dieser Information:

- Erkennen und Auswahl der Höchstgeschwindigkeit *LG1-L4*
- Erkennen von Haltestellen *EW8*
- Erkennen von Bereichen des Begegnungsverbots *EW9*
- Erkennen von Bereichen in denen entsprechend *EW4* Grennzeichen einen Halt nicht erlauben

- Erkennen von statischen Signalen zum Halten *EW4*, *EW5*
- Erkennen von weiteren Aktionen wie dem Auslösen des Signal- bzw. Weichenkontaktes *WA3*, dem Abgeben eines akustischen Signals *EW4* oder dem Abschalten des Fahrstromes für Streckentrenner *WA3*

Aufwendige kamerabasierte Verfahren, die sowohl für jede Witterung wie auch für jede Tageszeit eine hohe Erkennungsleistung aufweisen müssen und im Vergleich zu einer Karte aufwendiger zu validieren sind, können somit vermieden werden. Darüber hinaus beinhaltet die Karte wie zuvor aufgeführt die Position der LSA. Die genaue Umsetzung ist im Anschluss an die weitere Konkretisierung der Referenzarchitektur in Kapitel 4.4 beschrieben.

### 4.3.5 Lokalisierung

Zur Nutzung der Kartendaten ist eine Lokalisierung erforderlich. Diese kann auf verschiedene Weisen erfolgen, in anderen Domänen oder Forschungsanwendungen sind folgende Verfahren sowie Kombinationen derer üblich:

- GNSS
- Odometrie basierend auf Raddrehzahlen
- Odometrie basierend auf Inertialsensoren
- Landmarken, die mit der Umfeldsensorik erfasst werden
- Technische Einrichtungen im Gleis wie Balisen
- Magnet Signaturen der Szenerie<sup>124</sup> oder des Gleises<sup>125</sup>

Um die Komplexität zu reduzieren, wird als Teil der Referenzimplementierung eine Lokalisierung durch GNSS und Odometrie umgesetzt. Die Genauigkeit von GNSS kann grundsätzlich durch die Nutzung von kontinuierlich bereit gestellten Korrekturdaten im Rahmen des sogenannten *Differential Global Positioning Systems* erheblich verbessert werden.<sup>126, 127</sup> Dabei bestimmen festinstallierte Referenzstationen die Fehler in den Laufzeiten der Satellitensignale, welche insbesondere durch die Tropo- und Ionosphäre verursacht werden. Im Rahmen dieser Arbeit wurde für diese Korrekturdaten der SAPOS Dienst des Landes Hessen<sup>128</sup> sowie mobiles Internet verwendet. Als Erweiterung von *Differential Global Positioning System* (dPGS) ist die Genauigkeit unter Nutzung des sogenannten *Real Time Kinematic* (RTK) Verfahrens weiter

---

124 Heirich, O. et al.: Magnetic Measurements for Train Localization (2017).

125 Kröper, B. et al.: Fingerprint of Rails for Velocity Estimation and Localization (2020).

126 Morgan-Owen, G. J.; Johnston, G. T.: Differential GPS positioning (1995).

127 dGPS beschränkt sich entgegen dem Namen nicht nur auf GPS, sondern ist auch für andere Systeme wie GALILEO, GLONASS etc. verfügbar.

128 [www.sapos.hvbg.hessen.de](http://www.sapos.hvbg.hessen.de)

zu verbessern. Bei RTK werden nicht nur die Daten der Satellitensignale, sondern auch deren Trägerfrequenz selbst zur Abstandsbestimmung zwischen Satellit und Empfänger genutzt.<sup>129</sup> Der in der Versuchsbahn verbaute GNSS-Empfänger nutzt diese beiden Methoden und ermöglicht bei guten Empfangsbedingungen eine zentimetergenaue Positionsermittlung.<sup>130, 131</sup>

Die GNSS Position wird mittels Kartenabgleich auf den Verlauf der Schiene eingeschränkt. Die Nutzung des Kartenabgleichs erhöht die Genauigkeit der Lokalisierung<sup>132</sup> und ist aufgrund der Eindimensionalität des Aufenthaltsortes im Vergleich zu Kraftfahrzeugen vereinfacht. Für den Ausfall oder schlechten Empfang der Satellitendaten wird eine Odometrie verwendet. Ausfälle oder schlechter Empfang sind üblicherweise nicht nur durch Tunnel oder Überdachungen bedingt, sondern können auch in Gebieten mit dichter und hohe Bebauung, sogenannten „Häuserschluchten“, aufgrund von Abschattung und Mehrwegeausbreitung der Signale entstehen. Die genaue Umsetzung der Lokalisierung und Nutzung der Odometrie als Rückfallebene ist im nachfolgenden Kapitel zur Referenzimplementierung beschrieben.

### 4.3.6 Einzelne Verhaltensplanung

Die Beachtung des Begegnungsverbots mit entgegenkommenden Straßenbahnen nach *EW9* wird aufgrund der Ähnlichkeit der Handlung anhand von Karteninformationen in das Modul zur Berücksichtigung von Hindernissen integriert. Die Wahl von dynamisch geplanten Haltepunkten (vor Hindernissen, LSA etc.) berücksichtigt ebenfalls kartenbasiert Bereiche zusammenlaufender Gleise, in denen ein Halt nach *EW9* vermieden werden sollte.

Aufgrund des seltenen Vorkommens und zur Reduzierung des Implementierungsaufwandes im Rahmen dieser Untersuchung werden die kurzen Zwangshalte nach *EW4* als Haltestelle modelliert. Der Schutzhalt *EW5* nach Zeichen Sh 2, welcher die Weiterfahrt auf einem Gleis unterbindet, wird nicht als kontinuierlich geplantes Verhalten berücksichtigt, sondern im Rahmen der Referenzimplementierung als Teil des Fahrauftrages und der damit verbundenen Missionsplanung betrachtet und im Rahmen des Fahrauftrages als gegeben angenommen. Die Verhaltensanforderung *EW5* entfällt daher als Planungsmodul.

Entsprechend dieser bewusst außen vor gelassenen Funktionen reduzieren sich die Module der verschiedenen Einzelplanungen somit zu:

- Berücksichtigung von Hindernissen
- Halt an vorfahrtsregelnden LSA
- Halt an Haltestellen

---

129 Lee, I.-S.; Ge, L.: Performance of RTK-GPS (2006).

130 Swift Navigation: Duro Product Summary (2021).

131 Joubert, N. et al.: Modern GNSS and Its Impact on AV (2020).

132 Meng, Y. et al.: Simplified Map-Matching (2002).

- Auswahl und Regelung der Höchstgeschwindigkeit

### 4.3.7 Auswahl des Verhaltens

Die zu berücksichtigenden Verhaltensanforderungen werden getrennt als Sollbeschleunigung entlang der Gleise geplant. Es plant somit jedes Modul getrennt die Beeinflussung des eindimensionalen Freiheitsgrads der Straßenbahn. Zur Auswahl des umzusetzenden Verhaltens aus den einzelnen Modulen wird mit  $\min(a_i)$  das Verhalten mit der minimalen Beschleunigung als Grenzverhalten größter Kritikalität oder Einschränkung (bspw. im Falle von Haltestellen) ausgewählt.

### 4.3.8 Zusammenfassung der Konkretisierung

Es wurden zusätzliche Einschränkungen des Lösungsraums festgelegt und Lösungskonzepte für die einzelnen Module erarbeitet. Damit ist die allgemeine Referenzarchitektur aus dem vorherigen Kapitel in eine konkretisierte Architektur überführt. Abb. 4-6 fasst die Konkretisierung zusammen und zeigt die Verbindungen sowie Abhängigkeiten der Module. Wie beschrieben beschränkt sich die konkretisierte Referenzarchitektur aufgrund der Passivität von *Silent Testing* auf die Bereiche *Sense* und *Plan*, während *Act* vollständig entfällt.

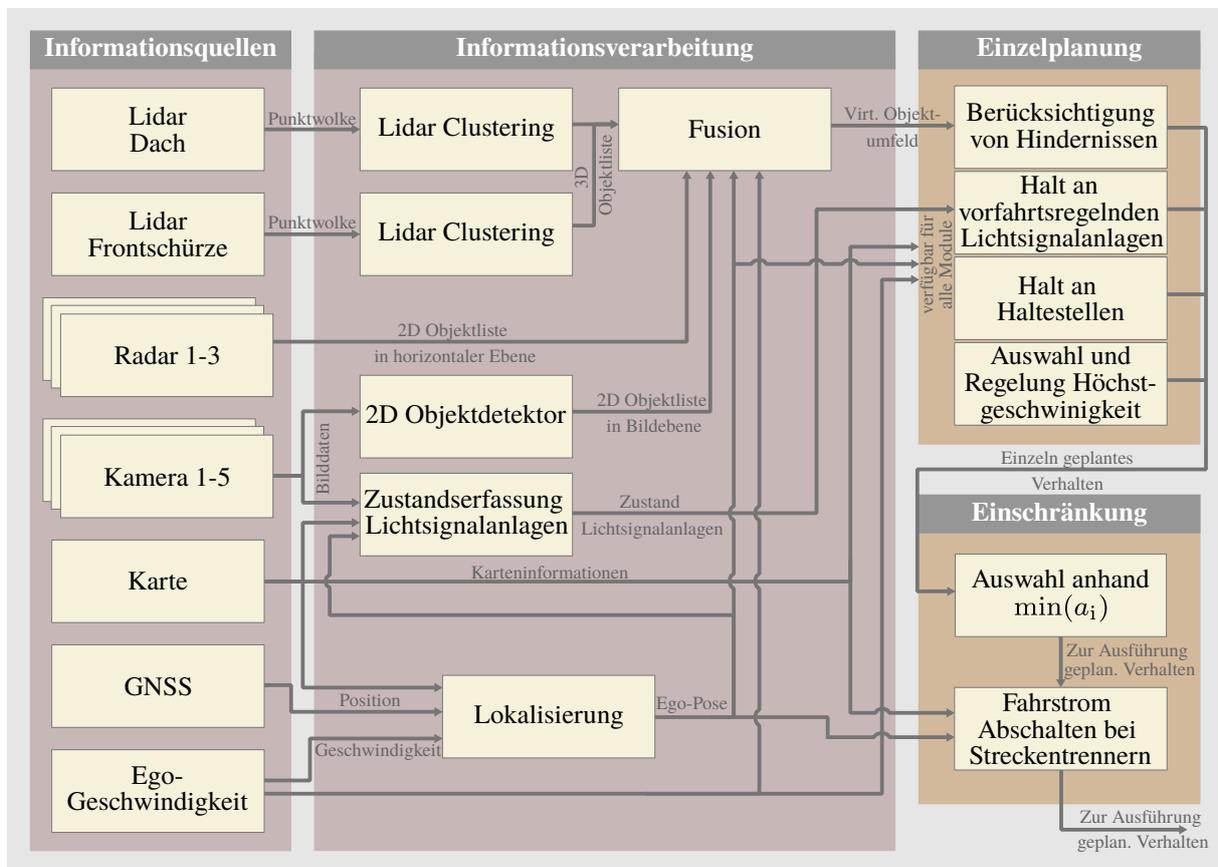


Abbildung 4-6: Konkretisierte Referenzarchitektur.

## 4.4 Referenzimplementierung

Für die aufgezeigten Module ist nachfolgend die technische Implementierung zur Realisierung eines OuT aufgezeigt. Aus der Untergruppe *Informationsquellen* (siehe Abb. 4-6) wird nur das Kartenmodul vorgestellt, da dieses nicht wie die anderen ein Zukaufteil als physisches Produkt darstellt, sondern basierend auf den genannten Anforderungen abgeleitet werden muss.

### 4.4.1 Karte<sup>133</sup>

#### Gleisverlauf

Die Grundlage der Karte bildet der Verlauf der Gleise. Während ein einzelnes Gleis verhältnismäßig einfach nur durch seine geodätischen Informationen beschrieben werden kann, muss die Modellierung eines ganzen Gleisnetzes auch die Topologie in Form von Weichen als Verbindungen, Kopfgleisen als Enden sowie unterschiedliche Fahrtrichtungen abbilden. In der Literatur werden Gleisnetze an besonderen Stellen in Abschnitte aufgeteilt.<sup>134, 135</sup> Im Bereich der Vollbahn existiert mit *RailTopoModel*<sup>136</sup> eine generische Beschreibungsform der Infrastruktur. In Adaption dieser Umsetzung werden Weichen und Endstellen ebenfalls als Randbedingungen betrachtet und das Straßenbahnnetz in einzelne Segmente unterteilt. Ein besonderer Vorteil im Zugbereich ist die Reduzierung der Position auf einen eindimensionalen Freiheitsgrad. Aufgrund der vorgegebenen Spurbreite wird die Datenrepräsentation nochmals vereinfacht, indem die linke und rechte Schiene eines Gleises zu einer virtuellen Mittellinie zusammengefasst werden.

Grundsätzlich können Kartendaten in 2D oder 3D sowie in verschiedenen Referenzsystemen dargestellt werden. Zur Nutzung der Schienenhöhe in Relation zu mit Sensoren bestimmten 3D Objekten wird die Darstellung des Verlaufs in 3D verwendet. Meist sind globale Positionen als ellipsoidische Koordinaten dargestellt, die in Breiten- und Längengraden sowie einer Höhe ausgedrückt werden. Diese Darstellung ist jedoch für die menschliche Vorstellung optimiert und basiert selbst auf einem zugrunde liegenden kartesischen Koordinatensystem, welches seinen Ursprung in der Erdmitte hat. Für die nachfolgend beschriebene Darstellung der Gleisverläufe als Splines eignet sich die gleiche Einheit und Skalierung aller Koordinaten. Aus diesem Grund erfolgt die Darstellung der Gleisverläufe in dem erdzentrierten und erdfesten kartesischen Koordinatensystem nach ETRS89.<sup>137</sup> Dieses ähnelt dem bekannten WGS84, berücksichtigt aber zusätzlich die europäische Kontinentalverschiebung, womit Koordinaten eine Langzeitstabilität

---

133 Einzelne Teile dieses Abschnittes wurden bereits veröffentlicht in: Ruppert, T. et al.: Map-Based Path and Pose for Trams (2021) © 2021 IEEE.

134 Heirich, O.: Localization of Trains and Mapping of Railway Tracks (2020), S. 51.

135 Böhringer, F.; Geistler, A.: Location in railway traffic (2006), S. 460.

136 Ciszewski, T. et al.: RailTopoModel and RailML (2017).

137 Altamimi, Z.; Boucher, C.: The ITRS and ETRS89 Relationship (2011).

bewahren. Üblicherweise geben GNSS-basierte Empfänger ihrer Positionsdaten mit 10–1000 Hz aus. Im Kombination mit einer geringen Geschwindigkeit während der Messung lässt sich so ein räumlich hochauflösender Verlauf der Gleise erheben. Hierzu sind einerseits spezielle Handwerkzeuge<sup>138</sup> möglich, andererseits können die Daten von einer Straßenbahn erhoben werden. Daher wurde ausschließlich zur Erhebung dieser Kartendaten eine Straßenbahn temporär mit der hochgenauen Lokalisierungslösung *Automotive Dynamic Motion Analyzer* (ADMA) der Firma GeneSys ausgestattet. Die eingesetzte ADMA-G Pro+ fusioniert verschiedene GNSS mit einer integrierten inertialen Messeinheit und ermöglicht so nicht nur bei gutem Empfang eine horizontale Genauigkeit von bis zu 1 cm,<sup>139</sup> sondern insbesondere eine Überbrückung der Positionsbestimmung bei GNSS-Ausfällen aufgrund von Häuserschluchten, Brücken, Bäumen und ähnlichen Abschattungen des Signals. Mit diesem Aufbau wurde das etwa 90 km lange Darmstädter Straßenbahnnetz vermessen. Die Messung erfolgte mit einer Frequenz von 100 Hz und die Geschwindigkeit betrug auf Überlandstrecken bis zu 50 km/h.

In der Literatur erfolgt die Darstellung von Straßen wie auch Gleisen in Kartendaten sowohl als Liste von diskreten Punkten<sup>140</sup> wie auch als mathematische Beschreibung in Form von Splines.<sup>141</sup> Im Gegensatz zu diskreten Punkten haben Splines den Vorteil, dass die Positionsdaten speichereffizienter dargestellt werden können, ohne durch eine Reduzierung der Punkte auf eine hohe räumliche Auflösung zu verzichten. Weiterhin ermöglichen Splines eine einfache Interpolation zwischen den einzelnen Punkten und lösen die unterschiedliche räumliche Auflösung bedingt durch Geschwindigkeitsänderungen während der Messung auf. Je nach Art des Splines sind diese stetig differenzierbar, was eine einfachere Bestimmung der linken und rechten Grenze des Kollisionsraumes anhand der virtuellen Mittellinie ermöglicht sowie ohne Knicke dem üblichen Verlauf von Gleisen entspricht. Die Nutzung eines Splines pro Segment erlaubt zusätzlich die einfache Referenzierung weiterer Informationen wie bspw. die Position von Haltestellen oder LSA anhand des eindimensionalen auf die Länge des Splines normierten Laufparameters  $s \in [0, 1]$ . Anhand der Ego-Lokalisierung des OuT ist die Position der Straßenbahn auf dem Spline bekannt. Der Abstand der Bahn zu referenzierten Elementen entlang des Gleisverlaufes ist somit direkt als Differenz der Laufparameter bestimmbar. Daher wird der Gleisverlauf jeden Segmentes als kubischer B-Spline dargestellt. Abb. 4-7 zeigt schematisch die Teilung des Gleisnetzes in Segmente und die Darstellung des Gleisverlaufes als Spline.

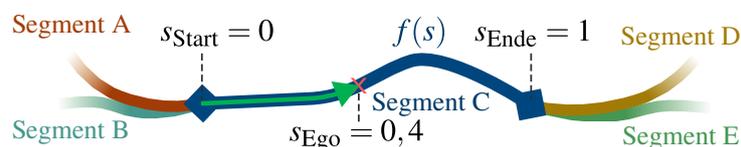


Abbildung 4-7: Schematische Kartendarstellung mit Splines.

138 Trimble Navigation: Produktbroschüre: Trimble GEDO Systeme (2023).

139 GeneSys: Datenblatt ADMA-G-Pro+ v35 (2023).

140 Bender, P. et al.: Lanelets (2014), S.420.

141 Hasberg, C. et al.: SLAM Path-Constrained Motion (2012), S. 541.

B-Splines ermöglichen einerseits als mathematische Randbedingung die exakte Vorgabe der Segment-Randbedingungen (Position der Weichen) und andererseits eine Glättung kleinerer Positionsfehler der Eingangsdaten. Aufgrund der dreidimensionalen Beschreibung der Messdaten im ETRS89 werden drei separate B-Splines benötigt, wobei jeder Spline die Verteilung der Punkte entlang einer der drei Koordinatenachsen beschreibt. Damit die B-Splines gemeinsam zur Rekonstruktion eines 3D-Punktes genutzt werden können, werden sie über den Laufparameter  $s$  synchronisiert. Für die Bestimmung eines diskreten 3D-Punktes sind daher pro Segment drei Splines für denselben Wert von  $s$  auszuwerten.

Die Erzeugung der Splines aus den diskreten Messdaten erfolgt nach einem Verfahren von Dierckx. Dieses berücksichtigt die Glättung der Eingangsdaten, indem während der Bestimmung der Spline-Parameter die Fehlerquadrate der Abweichung zwischen Spline und Eingangsdaten gegen die Unebenheit des Splines in Form der Ableitung abgewogen wird.<sup>142</sup>

### **Fahrzeugorientierung**

Für die Verknüpfung von geodätischen Kartendaten mit Informationen der Umfeldsensorik ist im Rahmen der Lokalisierung nicht nur die Position der Straßenbahn, sondern auch die Orientierung dieser zu bestimmen. Die Orientierung setzt sich dabei aus den drei Verdrehwinkeln zwischen dem Koordinatensystem der Karte sowie einem fahrzeugfesten Koordinatensystem der Bahn bzw. der Sensorik zusammen. Grundsätzlich könnte dies unmittelbar zwischen dem gewählten ETRS89 und dem Fahrzeugkoordinatensystem erfolgen, im Rahmen dieser Untersuchung wird jedoch in Anlehnung an ISO 8855<sup>143</sup> ein horizontiertes Zwischenkoordinatensystem für eine einfachere menschliche Deutung von Abweichungen gewählt. Für dieses in der Ebene der Schienenoberkante liegende Koordinatensystem wird der Ursprung unter dem ersten Drehgestell der Straßenbahn definiert. Dabei ist die erste Achse nach Osten, die zweite nach Norden und die dritte nach oben ausgerichtet. Hierbei handelt es sich somit um ein sich mit dem Fahrzeug bzw. ersten Wagenkasten bewegendes *East-North-Up* (ENU)-Koordinatensystem. Dies ermöglicht die Beschreibung der Drehung als Gieren, Nicken und Rollen zwischen ENU und dem Fahrzeugkoordinatensystem im ersten Wagenkasten der Straßenbahn, in dem sich die Umfeldsensorik befindet.

Die zusätzliche Verdrehung des örtlich gültigen ENU zum ETRS89, in dem die virtuelle Mittellinie des Gleises sowie Infrastrukturelemente beschrieben sind, ergibt sich aus der Definition des Referenzellipsoids innerhalb des ETRS89 selbst. Diese Verdrehung ändert sich aufgrund des geringen Einsatzgebietes kaum mit der Position der Straßenbahn, da sie vereinfacht ausgedrückt die lokale Krümmung der Erdoberfläche beschreibt. Die verschiedenen Koordinatensysteme sowie

---

142 Dierckx, P.: Curve and Surface Fitting with Splines (1995).

143 ISO 8855 gilt nur für Kraftfahrzeuge, wird jedoch aufgrund der Ähnlichkeit ebenfalls für die Definition der Orientierung der Straßenbahn verwendet. Jeder Wagenkasten kann ein eigenes Fahrzeugkoordinatensystem aufweisen, für die Relevanz der Sensorik wird jedoch nur der erste Wagenkasten betrachtet. Das Fahrzeugkoordinatensystem ist fest mit dem Aufbau also dem Wagenkasten und nicht mit dem Fahrwerk oder Drehgestell verbunden. Siehe auch ISO 8855: Road vehicles Vocabulary (2011).

exemplarisch die Definition des Gierwinkels, als einer der drei Verdrehwinkel, sind nachfolgend in Abb. 4-8 verdeutlicht.

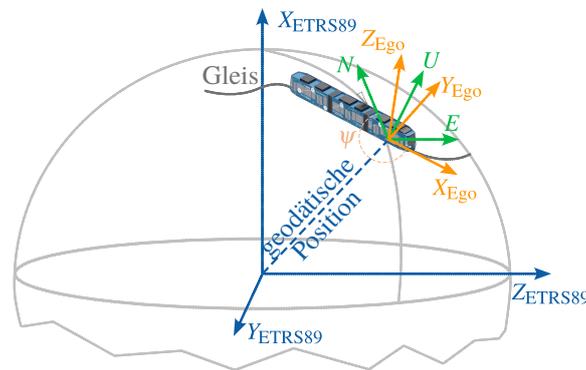
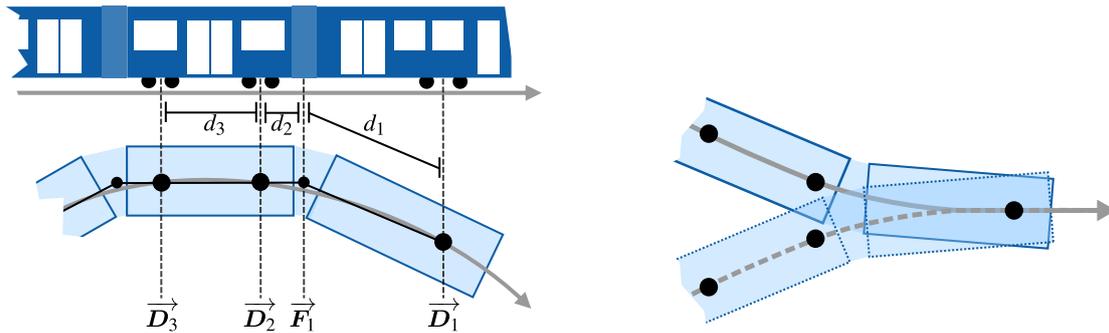


Abbildung 4-8: Koordinatensysteme der Karte. Basierend auf eigener Veröffentlichung<sup>133</sup> © 2021 IEEE.

Insbesondere die Korrektheit des Gierwinkels hat einen wesentlichen Einfluss für den gewünschten Zweck der Verknüpfung von Sensordaten mit Kartendaten. Als Beispiel wird für eine Anfangsgeschwindigkeit von 70 km/h (max. Geschwindigkeit für den Betrieb auf Sicht) der in der BOStrab vorgeschriebene maximale Notbremsweg von 69 m betrachtet. So ergibt sich mit einer exemplarischen Unsicherheit von  $\pm 1^\circ$  für die Bestimmung des Gierwinkels ein seitlicher Fehler von bereits etwa 1,20 m in 69 m Entfernung. Dieser Fehler wirkt sich unmittelbar auf die Zuordnung aus, ob ein Objekt auf oder neben den Gleisen ist. Während der gleiche Winkelfehler für Nicken und Rollen zwar den gleichen räumlichen Fehler verursacht, ist er von geringerer Bedeutung, da Neigungs- und Rollfehler im wesentlichen Unterschiede in der Höhenzuordnung verursachen. Deren Auswirkungen können robuster gestaltet werden, da sich potenzielle Hindernisse normalerweise entlang des Bodens bewegen.

Für schienengebundene Fahrzeuge ergibt sich der Vorteil, dass die Drehgestelle bzw. Laufwerke an das Gleis gebunden sind und sich somit basierend auf dem Gleisverlauf und der Fahrzeugkinematik<sup>144</sup> für jede Position entlang des Gleises eine eindeutige Orientierung des Fahrzeuges ergibt. Den Zusammenhang zwischen Gleisverlauf und Fahrzeugkinematik verdeutlicht Abb. 4-9 (a). Für die hier betrachtete Versuchsbahn ist nur die Orientierung des ersten Wagenkastens relevant, da nur in diesem die Sensoren zur Umfelderkennung verbaut sind. Die Versuchsbahn weist im ersten Wagenkasten nur ein Drehgestell  $\vec{D}_1$  und im zweiten Wagenkasten zwei Drehgestelle  $\vec{D}_2$  und  $\vec{D}_3$  auf. Der erste und zweite Wagenkasten sind über ein Gelenk in einem Faltenbalg  $\vec{F}_1$  verbunden. Mathematisch ist der Zusammenhang zwischen Gleisverlauf und der sich einstellenden Orientierung für eine gegebene Position des bspw. ersten Drehgelenks  $\vec{D}_1$  über ein nicht lineares Gleichungssystem beschrieben. Für andere Straßenbahn Modelle, die andere Abstände  $d$  zwischen diesen Punkten oder zwei Drehgestelle im ersten Wagenkasten haben, ergibt sich eine andere Orientierung.

144 Unter der Annahme eines verdrehsteifen Fahrzeugs.



(a) Kinematik der Versuchsbahn. *Basierend auf eigener Veröffentlichung<sup>133</sup> © 2021 IEEE.* (b) Doppeldeutigkeit der Orientierung unmittelbar nach Weichen.

Abbildung 4-9: Zusammenwirken Kinematik und Gleisverlauf.

Für die hier aufgezeigte Referenzimplementierung wird die Orientierung der Versuchsbahn a priori in einer Karte gespeichert. Die Bestimmung der Ego-Pose im Rahmen der Lokalisierung ist somit auf eine Bestimmung der Position und den Abruf der zugehörigen Orientierung reduziert. Wie jedoch Abb. 4-9 (b) zeigt, existiert einerseits aufgrund der Ausdehnung der Bahn eine Abhängigkeit über Segmentgrenzen hinweg und andererseits gibt es im Fall von in Fahrtrichtung zusammenlaufenden Gleisen eine Doppeldeutigkeit der Orientierung für ein und dieselbe Position. Diese Doppeldeutigkeit beschränkt sich dabei im Fall der Versuchsbahn auf den Bereich  $d_1 + d_2 + d_3$  ab der Weiche. Durch die zusätzliche Betrachtung der bereits befahrenen Segmente als Gedächtnis wird diese Doppeldeutigkeit im Rahmen der Referenzimplementierung aufgelöst und der korrekte a-priori bestimmte Verlauf der Orientierung gewählt.

Zur effizienten Speicherung und einem einfachen Abruf werden die zuvor bestimmten Orientierungswinkel ebenfalls als eindimensionale B-Splines synchron zu den Splines des Gleisverlaufs erzeugt. Dies ermöglicht die Nutzung des im Rahmen der Lokalisierung bestimmten Laufparameters  $s$  zur einfachen Ermittlung der Orientierung. Abb. 4-10 zeigt einen Ausschnitt der Karte mit dem Gleisverlauf und dem visualisierten Gierwinkel als einer der drei Orientierungswinkel.

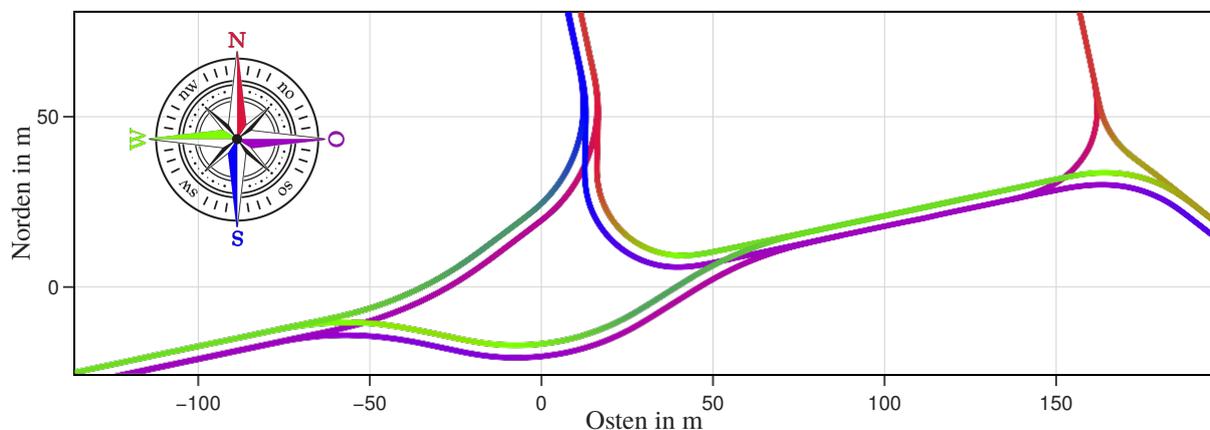


Abbildung 4-10: Ausschnitt der splinebasierten Karte mit farbig visualisiertem Gierwinkel. Ein Gleis ist nicht als zwei Schienen, sondern durch die virtuelle Mittellinie dargestellt.

Die Bestimmung der Orientierung im Vorfeld kann numerisch als nicht-lineares Optimierungsproblem der Fahrzeugkinematik und des Gleisverlaufs als Randbedingung formuliert werden<sup>133</sup> oder einmalig sensorisch vermessen werden. Im Rahmen der durchgeführten Messfahrten für die Positionen des Gleisverlaufes sind auf Basis der faseroptischen Kreisel der eingesetzten ADMA auch die drei Verdrehwinkel zwischen ENU und dem ersten Wagenkasten erfasst. Die Orientierung der Versuchsbahn wurde somit einmalig mit einer Genauigkeit<sup>139</sup> der ADMA von bis zu  $0,01^\circ$  vermessen und in der Karte hinterlegt. Es ist zu berücksichtigen, dass die Orientierung durch elastische Verformungen im Fahrwerk und in den Verbindungsteilen nicht konstant ist und auch die Positionsbestimmung nicht fehlerfrei erfolgt. Die Genauigkeit der Messung entspricht daher nicht der Genauigkeit beim Abruf der Orientierung im Rahmen des OuT.

Zur Plausibilisierung des Vorgehens wurde ein Teilstück von etwa 235 m mit einer etwa  $90^\circ$  Biegung insgesamt 20-mal an fünf verschiedenen Tagen mit einer ADMA in einer Straßenbahn vermessen und die drei Orientierungswinkel für Gieren, Rollen und Nicken näher analysiert. Während wie unten näher erläutert der Fehler für die Bestimmung des Gier- und Nickwinkels akzeptabel ist, hat sich gezeigt, dass der Rollwinkel bereits im Rahmen der Messungen (also noch nicht als Spline) während Kurvendurchfahrten um  $1,3^\circ$  schwankt. Diese Schwankung ist mutmaßlich auf die unterschiedlichen Fahrzeuggeschwindigkeiten in Kombination mit der Trägheit des Aufbaus sowie dem Fahrwerk zurückzuführen.<sup>133</sup> Aufgrund der Schwankung des Rollwinkels und dessen geringer Auswirkung zwischen Sensor- und Kartendaten (vornehmlich ein Höhenunterschied), wird der Rollwinkel im Rahmen der Referenzimplementierung nicht vorab in der Karte gespeichert und auch im Rahmen der Lokalisierung nicht weiter berücksichtigt.

Zwar unterliegt auch der Nickwinkel ähnlichen dynamischen Effekten durch die Kombination von Fahrwerk und Trägheit des Aufbaus wie der Rollwinkel, jedoch treten verursacht durch Berg- und Talfahrten deutlich größere nicht-dynamische Änderungen des Nickwinkels auf. So beträgt der maximale Nickwinkel in Darmstadt etwa  $3,7^\circ$ . Tabelle 4-2 zeigt die aufgetretenen Fehler zwischen der kartenbasierten Bestimmung des Gier- bzw. Nickwinkels und den 20 Messungen. Aufgrund der geringen Fehler wird das Verfahren in der Referenzimplementierung eingesetzt und als neuartige straßenbahnspezifische Automatisierungslösung betrachtet, deren Plausibilität durch die Anwendung von *Silent Testing* geprüft wird. Zusätzliche dynamische Effekte durch das Fahrwerk sind im Rahmen der Referenzimplementierung nicht berücksichtigt, grundsätzlich als zukünftige Erweiterung jedoch denkbar.

Tabelle 4-2: Fehler a-priori bestimmte Orientierung.

Fehlerart	Gierwinkel $\psi$	Nickwinkel $\theta$
Mittlere absolute Abweichung	$0,06^\circ$	$0,16^\circ$
Maximale Abweichung	$0,33^\circ$	$0,37^\circ$

## Infrastrukturelemente

Entsprechend der konkretisierten Referenzarchitektur sind alle Verkehrszeichen, Markierungen und LSA in der für das OuT verwendeten Karte hinterlegt. Dazu sind die betrachteten Elemente des Darmstädter Straßenbahnverkehrs von Hand vermessen und die geodätischen Positionsdaten mit zusätzlichen Metainformationen angereichert.

- Für Geschwindigkeitsänderungen und Ankündigungen dieser sind zugehörige Geschwindigkeitswerte sowie bei Bedarf Einschränkungen bezüglich der gültigen Uhrzeit hinterlegt.
- Bei LSA sind die anzeigbaren Signale hinterlegt. Im Gegensatz zu den LSA des Kraftfahrzeugbereiches existieren keine markierten Haltelinien. Auf Basis menschlicher Durchschnittswerte an ausgewählten LSA wurde für jede LSA ein virtueller Haltepunkt bestimmt. An Weichen gibt es LSA für die unterschiedlichen Richtungen, für eine Zuordnung sind zusätzlich die zugehörigen Fahrrichtungen als Referenz auf das jeweilige nachfolgende Segment hinterlegt.
- Haltestellen sind mit den entsprechenden Haltelinien und den dazugehörigen Namen sowie den Besonderheiten bezüglich der Gültigkeit wie z. B. abweichende Haltepunkte im Betrieb mit Beiwagen versehen. Temporäre Abweichungen durch Baustellen sind mit zusätzlichen gültigen Zeiträumen hinterlegt.

Die gemessenen Elemente sind je nach Gültigkeit einem oder im Bereich von Weichen mehreren Segmenten zugeordnet. Neben der Beziehungsbeschreibung zwischen Segment und Element wird zusätzlich die Lage des Elements entlang des jeweiligen Laufparameters  $s$  gespeichert, um als Teil der nachfolgend beschriebenen Verhaltensplanung den Abstand zwischen Ego-Position und Element entlang der Schiene durch einfache Differenzbildung zu bestimmen. Einen Überblick über die Anzahl an vermessenen Elementen gibt Tabelle 4-3.

Tabelle 4-3: Vermessene punktuelle Infrastruktur.

	<b>Verkehrszeichen &amp; Markierungen</b>	<b>Haltestellen bzw. Haltelinien</b>	<b>Lichtsignalanlagen</b>
<b>Anzahl</b>	243	184	409

### 4.4.2 Lokalisierung

Basierend auf der konkretisierten Referenzarchitektur beruht die Lokalisierung auf der Positionsbestimmung mittels RTK GNSS und Kartenabgleich sowie einer Odometrie für GNSS Ausfälle. Für einen einfachen Kartenabgleich ist die GNSS Antenne auf der Versuchsbahn mittig über dem ersten Drehgestell auf dem Dach angebracht. Abgesehen von lateralen Abweichungen durch Rollen ist die Antenne somit im Gierzentrum des ersten Wagenkastens und damit stets

oberhalb der virtuellen Mittellinie des in der Karte hinterlegten Gleisverlaufs. Wäre die Antenne weiter vorne oder hinten angebracht, wären beim Kartenabgleich insbesondere die longitudinalen Positionsänderungen der Antenne durch Gierbewegungen zu berücksichtigen. Dies wäre jedoch aufgrund der kartenbasierten Bestimmung der Orientierung erschwert. Für einen einfachen Kartenabgleich wird für jede bestimmte GNSS Position derjenige Gleisabschnitt mit der geringsten horizontalen Abweichung von der virtuellen Mittellinie bestimmt. Dazu werden die GNSS Positionsdaten und virtuellen Mittellinien der Splines  $\mathcal{S}$  der umgebenden Segmente in ein ENU Koordinatensystem transformiert und die Distanz in Ost ( $E$ ) und Nord ( $N$ ) unter Variation des Laufparameters  $s$  des betrachteten Segment-Splines minimiert. Abweichungen durch Rollen oder Überhöhungen des Gleisbettes in Kurven haben somit keinen wesentlichen Einfluss auf die Bestimmung von  $s$ , da es sich dabei um eine rein laterale Verschiebung zur Kurveninnen- oder Außenseite handelt.

$$\begin{aligned} \min_s \quad & (E_{\text{GNSS}} - E_{\mathcal{S}}(s))^2 + (N_{\text{GNSS}} - N_{\mathcal{S}}(s))^2 \\ \text{unter} \quad & s \in [0, 1] \end{aligned} \quad (4-1)$$

Für den vorübergehenden Ausfall von GNSS oder Teilverschattungen, bei denen kein RTK für eine präzise Positionsbestimmung zur Verfügung steht, wird die neue Ego-Position mittels Odometrie geschätzt. In der Versuchsbahn wird die Ego-Geschwindigkeit durch eine Bestimmung an mehreren Achsen mit geringem Schlupf ermittelt. Diese steht zu diskreten Zeitpunkten  $t_i$  zur Verfügung. Die Position zu einem beliebigen Zeitpunkt wird somit aufbauend auf der zuletzt validen GNSS basierten Position  $\bar{s}_{\text{ego}}$  durch numerische Integration bestimmt.

$$\begin{aligned} s_{\text{ego}} &= \bar{s}_{\text{ego}} + \Delta s \\ \Delta s &= \sum_{i=1}^N (t_i - t_{i-1}) \cdot v_{\text{ego},i} \end{aligned} \quad (4-2)$$

### 4.4.3 Lidar Clustering

Im Rahmen von Lidar Clustering werden die einzelnen Punkte einer Lidar Punktwolke zu getrennten Objekten zusammengefasst und diese so innerhalb der Punktwolke identifiziert. Im Gegensatz zur 3D-Objektdetektion wird dieses Verfahren als traditionelle Methode der Lidar-auswertung betrachtet. Allen Clustering-Methoden für Lidar ist gemeinsam, dass der Boden vor der Clusterbildung herausgefiltert werden muss. Andernfalls würden die Reflexionspunkte des Bodens fälschlicherweise mit den zu identifizierenden Objekten zu einem großen Cluster zusammengefasst werden. Im Bereich der Kraftfahrzeuge werden dafür häufig Methoden verwendet, die von einer ebenen oder nur gering gekrümmten Oberfläche ausgehen. Bspw. wird häufig der sogenannte RANSAC-Algorithmus<sup>145</sup> genutzt, bei dem mittels zufälliger Stichproben

145 Fischler, M. A.; Bolles, R. C.: Random sample consensus (1981).

in der Punktwolke die größte Übereinstimmung mit einer Ebene identifiziert wird. Auch wenn die Annahme des ebenen Bodens bereits bei Kraftfahrzeugen versagt, ist die Anforderung zur Identifikation eines gekrümmten Bodens für Straßenbahnen nochmals bedeutsamer. Insbesondere bei Strecken außerhalb der Stadt ist die Gleislage zumeist als Einschnitt oder Damm ausgeführt, welche wie das offene Gleis selbst nicht durch eine einzige Ebene angenähert werden können. Aus diesem Grund wird im Rahmen der Referenzimplementierung ein Bodenfilter umgesetzt, welches keine globale gerade Fläche sucht, sondern Punkte einzeln anhand lokaler Steigungen klassifiziert.<sup>146</sup> Für einen Punkt der Punktwolke wird die Steigung zu den unmittelbaren Nachbarn innerhalb einer Ebene des Lidars (Ebene im Sinne der vertikalen Strahlverteilung) sowie zur nächsten und vorherigen Ebene in einem horizontierten Koordinatensystem bestimmt. Unterschreitet die Steigung einen zuvor festgelegten Grenzwert, wird eine Gruppe an möglichen Bodenpunkten gebildet. Überschreitet die Gruppe eine ebenfalls zuvor festgelegte Größe, gilt die Gruppe als Boden und wird für das nachfolgenden Clustering aus der Punktwolke entfernt. Zusätzlich wird ein entfernungsabhängiger Grenzwert für die absolute Höhe berücksichtigt um so gezielt Punkte, die eine gewisse Höhe überschreiten, nicht fälschlich als Boden zu klassifizieren.

Als zusätzliches Filter werden als Teil der Referenzimplementierung alle Punkte über der von der Straßenverkehrs-Ordnung gesetzlich erlaubten Fahrzeughöhe<sup>147</sup> von 4,0 m über der Schienenoberkante der Ego-Position entfernt. Damit sind Lkw, Busse und andere Straßenbahnen weiterhin inkludiert, insbesondere Reflexionen von Gebäuden werden hingegen reduziert, die als statische Objekte nicht von Relevanz sind, aber den Rechenaufwand erhöhen. Darüber hinaus wird mit diesem Filter die Fahrleitungsanlage oberhalb der Straßenbahn entfernt und kann so nicht fälschlich als Hindernis erkannt werden.

Zur analytischen Bildung der Cluster können verschiedene Methoden und Metriken zur Bildung eines Ähnlichkeitsmaßes zum Einsatz kommen. Grundsätzlich kann zwischen drei Ansätzen unterschieden werden, die in der Literatur in ähnlichem Maße und teilweise in Kombination angewendet werden.<sup>148</sup> Die Motivation der verschiedenen Methoden und deren Implementierungen ist die notwendige Rechenleistung, besonders bei der Abwägung der Genauigkeit der Segmentierung.

**Euklidische Distanz:** Die Punkte werden basierend auf dem euklidischen Abstand zueinander und mittels Schwellwert in Cluster zusammengefasst. Nachteilig an diesem Verfahren ist, dass die Punkte für weiter entfernte Objekte aufgrund der Winkelauflösung und damit radialen Aufweitung der Abtastung einen höheren Abstand zwischen benachbarten Lidarstrahlen aufweisen, auch wenn sie auf das gleiche Objekt treffen. Darüber hinaus ist der Rechenaufwand durch den Vergleich aller Elemente einer Punktwolke untereinander für die Bestimmung der euklidischen Distanz vergleichsweise hoch. Es existieren jedoch

---

146 Nagoya University; Autoware Foundation: Ray Ground Filter (2017).

147 BGBI: Straßenverkehrs-Ordnung (2013), § 22.

148 Zhao, Y. et al.: Survey of Traditional Point Cloud Clustering Methods (2021).

verschiedene Optimierungen, um die Berechnung zu beschleunigen. So kann bspw. die Berechnung nur im zweidimensionalen Raum<sup>149</sup> erfolgen.

**Supervoxel und ähnliche:** Ähnlich zu Superpixeln aus der Bildverarbeitung entsprechen sogenannte Supervoxel kleineren zusammenhängenden volumetrischen Regionen, die meist iterativ wachsend gebildet werden. Dazu können z. B. eine lokale euklidischer Distanz oder Ähnlichkeiten von Intensitäten verwendet werden. Insbesondere ist DBSCAN<sup>150</sup> ein häufig verwendeter dichtebasierter Algorithmus zur Bildung von Clustern.<sup>151</sup> Sofern die Supervoxel eine Übersegmentierung darstellen, ist auch eine Zusammenfassung der Supervoxel zu größeren Objekten möglich.

**Tiefenbild:** Die Bildung von Clustern ist auch mittels Tiefenbild, ähnlich dem einer Stereokamera, möglich. Der Vorteil des Tiefenbildes ist, dass Nachbarschaftsbeziehungen implizit in der 2D Position innerhalb des Tiefenbildes gegeben und Rechenoperationen zumeist schneller als im dreidimensionalen kartesischen Raum sind.<sup>152a</sup> Punkte eines Objektes, die von zwei benachbarten Laserabtastungen stammen, tauchen im Tiefenbild als benachbarte Pixel auf. Dies reduziert in erster Linie die Anzahl der zu miteinander prüfenden Punkte und somit die erforderliche Rechenleistung, zumal Lidarsensoren neben der 3D-Punktwolke meist auch ein Tiefenbild zur Verfügung stellen. Unabhängig der reduzierten Anzahl an zu prüfenden Elementen ist weiterhin ein Maß zur Bestimmung der Ähnlichkeit wie z. B. die Abweichung der Tiefe oder der Distanz der Punkte zueinander erforderlich.

Alle Methoden weisen spezifische Vor- und Nachteile auf. Im Rahmen der Referenzimplementierung wurde aufgrund der reduzierten Rechenlast, der Verfügbarkeit als Basis der Implementierung sowie der Popularität der zugehörigen Quellcodeveröffentlichung ein auf Tiefenbildern basierender Ansatz von Bogoslavskyi und Stachniss gewählt.<sup>152b, 153, 154</sup> In diesem Ansatz wird die Punktwolke als 2D-Bild dargestellt, bei dem eine frei wählbare Anzahl an Nachbarn eines Pixels und somit benachbarte Lidarstrahlen hinsichtlich ihrer Zugehörigkeit zu einem Objekt geprüft werden. Im Vergleich zum vollständigen euklidischen Vergleich aller Punkte untereinander ist der Rechenaufwand dabei stark reduziert. Als Ähnlichkeitsmaß zwischen zwei Punkten wird nicht die euklidische Distanz, sondern wie in Abb. 4-11 dargestellt der distanzunabhängige Winkel  $\beta$  zwischen zwei Punkten bestimmt. Die Zusammengehörigkeit zu einem Objekt wird mittels unterem Grenzwert  $\beta_{\min}$  geprüft. Dazu ist nachfolgend links in Abb. 4-11 (a) die Definition von  $\beta$  sowie auch die Veränderung des Winkels je nach Zugehörigkeit der Punkte gezeigt. Für den hypothetisch dargestellten Fall ist der Winkel  $\beta_1$  zwischen zwei Reflexionen eines Objektes

---

149 Korchev, D. et al.: Real-Time LIDAR Data Segmentation (2013).

150 Ester, M. et al.: Density-based algorithm in large spatial databases (1996).

151 Wang, C. et al.: Improved DBSCAN Method for LiDAR Data + (2019).

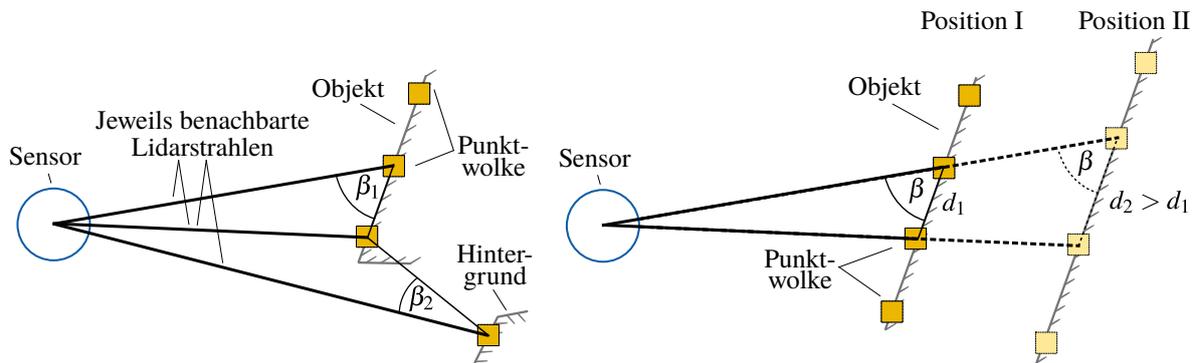
152 Bogoslavskyi, I.; Stachniss, C.: Fast range image-based segmentation (2016) a: S. 165, b: -.

153 Bogoslavskyi, I.; Stachniss, C.: Efficient Online Segmentation for Sparse 3D Laser Scans (2017).

154 Photogrammetry & Robotics Bonn: Depth Clustering (2016).

größer als der Winkel  $\beta_2$  zwischen der Reflexion am Objekt und einem weiter entfernten Punkt im Hintergrund. Somit kann mit geeigneter Wahl von  $\beta_{\min}$  die Zusammengehörigkeit von Punkten zu einem Objekt bestimmt werden, während Reflexionen im Hintergrund als eigenständige weitere Objekte erkannt werden.

Ein wesentlicher Vorteil bei der Anwendung von  $\beta$  als Clustermetrik im Vergleich zur häufig verwendeten euklidischen Distanz besteht darin, dass  $\beta$  unabhängig von der räumlichen Entfernung zwischen dem Sensor und dem betrachteten Objekt ist. Wie nachfolgend rechts in Abb. 4-11 (b) dargestellt, würde ein weiter entferntes Objekt an Position II für das betrachtete Punktpaar den gleichen Winkel  $\beta$  aufweisen, wie an einer näheren Position I. Im Gegensatz dazu wäre aufgrund des Strahlprinzipes der Abstand zwischen den Punkten an Position II größer als für Position I.



- (a) Der Winkel  $\beta_1$  ist für Reflexionen, die zu einem Objekt gehören, größer als der Winkel  $\beta_2$  für Reflexionen zwischen dem Objekt und etwas anderem im Hintergrund.
- (b) Distanzunabhängigkeit von  $\beta$ . Wäre das gleiche Objekt weiter entfernt (II), so wäre der Winkel  $\beta$  gleich, aber die euklidische Distanz zwischen den Detektionen benachbarter Strahlen größer.

Abbildung 4-11: Definition und Wirkweise von  $\beta$  zur Clusterbildung. Die Detektionen des Lidars sind mit  $\blacksquare$  bzw.  $\square$  für die weiter entfernte Position mit  $\square$  dargestellt.

Die Cluster stellen nach der Segmentierung der Punktwolke die Objekte der Umgebung als Anhäufung von Punkten dar. Diese Darstellung ist jedoch aufgrund der Vielzahl der Punkte sowie möglicher Lücken durch Verschattungen nicht geeignet, um Objekte als potenzielle Hindernisse einzuordnen oder zu fusionieren. Als datenreduzierte Darstellung im Bereich der automatisierten Kraftfahrzeuge werden üblicherweise 3D-Boundingboxen oder 2D-Polygone genutzt. Boundingboxen bieten den Vorteil, dass sie die vom Sensor abgewendete und somit von diesem nicht erfasste Seite eines Objekts approximieren. Nachteilig ist jedoch, dass die Approximation nur für starre, möglichst viereckige Körper gilt. Dies trifft z. B. bei abbiegenden Lastkraftwagen nicht zu, da es durch die Verdrehung zwischen Zugmaschine und Auflieger zu einer veränderlichen Außenkontur kommt. Zudem muss mittels Algorithmus aus der isolierten Anhäufung von Punkten eine viereckige Box ermittelt werden. Dies ist insbesondere erschwert, wenn das Cluster nur über wenige Punkte verfügt (bspw. an FoV Rändern der Sensoren) oder verhältnismäßig viele der Punkte von der Objektobenseite (bspw. Windschutzscheiben oder Fahrzeugdächer) anstatt von den Seiten stammen. Eine falsche Approximation mittels Boundingbox kann das Objekt größer abschätzen, als es in der Realität tatsächlich ist. Wie nachfolgend in Abb. 4-12 (a)

dargestellt, kann dies wiederum einen geringeren Abstand zum Gleisverlauf bedeuten und so ein Objekt fälschlicherweise als Hindernis eingeordnet werden. Aus diesem Grund wird im Rahmen der Referenzimplementierung aus den Lidar Punkten des Objektes die einhüllende konvexe Form als 2D-Polygon mit zusätzlicher Objekthöhe anstatt als starre Boundingbox bestimmt. Wie Abb. 4-12 (b) zeigt, schließt das konvexe Polygon alle Punkte ein. Jedoch wird durch die anliegende Form des Polygons im Gegensatz zu einer Boundingbox die vom Sensor abgewendete Seite des Objektes nicht richtig beschrieben. Diese ist nicht von weiterer Relevanz, da für die Klassifikation als unmittelbares oder zukünftiges Hindernis die zur Schiene bzw. zur Straßenbahn gewandte Seite ausschlaggebend ist und diese, abgesehen von anderen Verdeckungen, von den Lidarsensoren erfasst wird. Den Nachteil der fälschlicherweise zu großen Abschätzung der Objektform lösen jedoch auch konvexe Polygone nicht vollständig, wie in Abb. 4-12 (c) gezeigt ist. In einer Voruntersuchung hat sich gezeigt, dass besonders in Rechts-Kurven entgegenkommende Straßenbahnen oder Busse aufgrund ihrer langen Form und den Drehgelenken sowie Faltenbälgen mit einem konvexen Polygon mit einer zu großen Außenkontur ähnlich starrer Boundingboxen beschrieben werden. Dies führt dazu, dass die entgegenkommende Bahn oder der Bus zu nah zum Ego-Gleis abgeschätzt und somit fälschlich als Hindernis eingeordnet wird. Aus diesem Grund wird in der Referenzimplementierung für alle längeren Objekte das einhüllende Polygon als nicht-konvexe Form bestimmt. Ein nicht-konvexes Polygon erlaubt nach Innen zeigende Kanten, verbindet aber im Gegensatz zu einem streng konkaven Polygon nicht alle Punkte als Außenhülle. Da die Bestimmung einer nicht-konvexen Form bezüglich der Rechenkomplexität aufwendiger ist und ein konvexes Polygon für normale Kraftfahrzeuge ausreichend ist, wird das nicht-konvexe Polygon nur für Objekte mit einer Länge von mehr als 5 m bestimmt. Die Länge wird mittels einer zuvor einfachen — und wie in Abb. 4-12 (a) gezeigten möglicherweise verdrehten — Boundingbox geschätzt. Das genutzte Berechnungsverfahren<sup>155</sup> erlaubt die Festlegung eines unteren Längenschwellwerts für Kanten, ab welchem diese nicht weiter in nach innen zeigende Kanten unterteilt werden. Dieser wurde für die Referenzimplementierung als Kompromiss zwischen Anzahl an Stützstellen und damit Berechnungsaufwand für nachfolgende Algorithmen sowie hinreichender Beschreibung in Kurvenfahrten auf 2,0 m festgelegt.

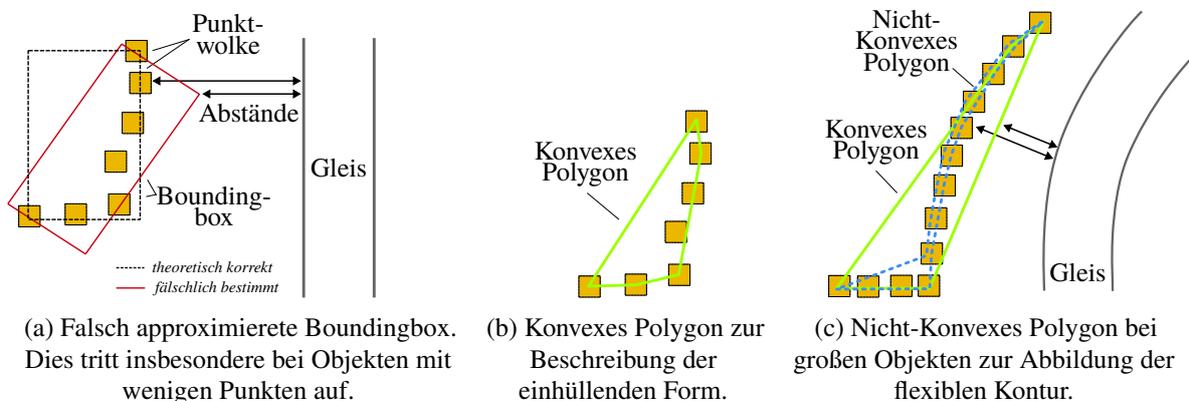


Abbildung 4-12: Beschreibung der mittels Lidar detektierten Objektkontur

155 Jin-Seo Park; Se-Jong Oh: Concave Hull Algorithm (2012).

Die in der Versuchsbahn verbauten Lidarsensoren werden separat mithilfe des oben beschriebenen Verfahrens ausgewertet, da eine einfache Kombination der Punktwolken zu Verschiebungen durch Bewegungsunschärfe führt. Die beiden eingesetzten Sensoren erfassten mit einer Frequenz von 10 Hz bzw. 25 Hz die Umgebung. Wird als konservative Abschätzung der Zeitverzug zwischen den Punktwolken der beiden Sensoren als  $1/25 \text{ s} = 40 \text{ ms}$  sowie eine Fahrt mit der Höchstgeschwindigkeit für *Fahren auf Sicht* von 70 km/h angenommen, ergibt sich für die Punkte stehender Objekte bereits eine Verschiebung um etwa 78 cm. Zwar wäre diese durch die Ego-Bewegung der Straßenbahn verursachte Verschiebung durch eine vorherige Transformation in ein ortsfestes Koordinatensystem kompensierbar, nicht jedoch die unterschiedlichen Bewegungen von umgebenden dynamischen Objekten.

Abb. 4-13 fasst für den auf dem Dach verbauten Lidarsensor Velodyne VLP-32C die Verarbeitung zusammen. Die vom Sensor bereit gestellte Punktwolke ist entsprechend der Intensität der Reflexion gefärbt, wie Abb. 4-13 (a) zeigt. Die Betrachtung der Lidar Punktwolken erfolgt von der Bahn aus betrachtet von hinten oben rechts. Das Filtern des Bodens und aller Punkte über 4,0 m entfernt eine Vielzahl der Punkte, übrig bleiben die in Abb. 4-13 (c) gezeigte Punktwolke in der Verkehrsteilnehmer aber auch Infrastruktur wie LSA oder Gebäude enthalten sind. Die mittels Tiefenbild erzeugten Cluster sowie die zugehörigen 2D Polygone sind farbig bzw. als grüne Umrandungen in Abb. 4-13 (d) dargestellt. In dieser Beispielszene sind alle Polygone konvex.

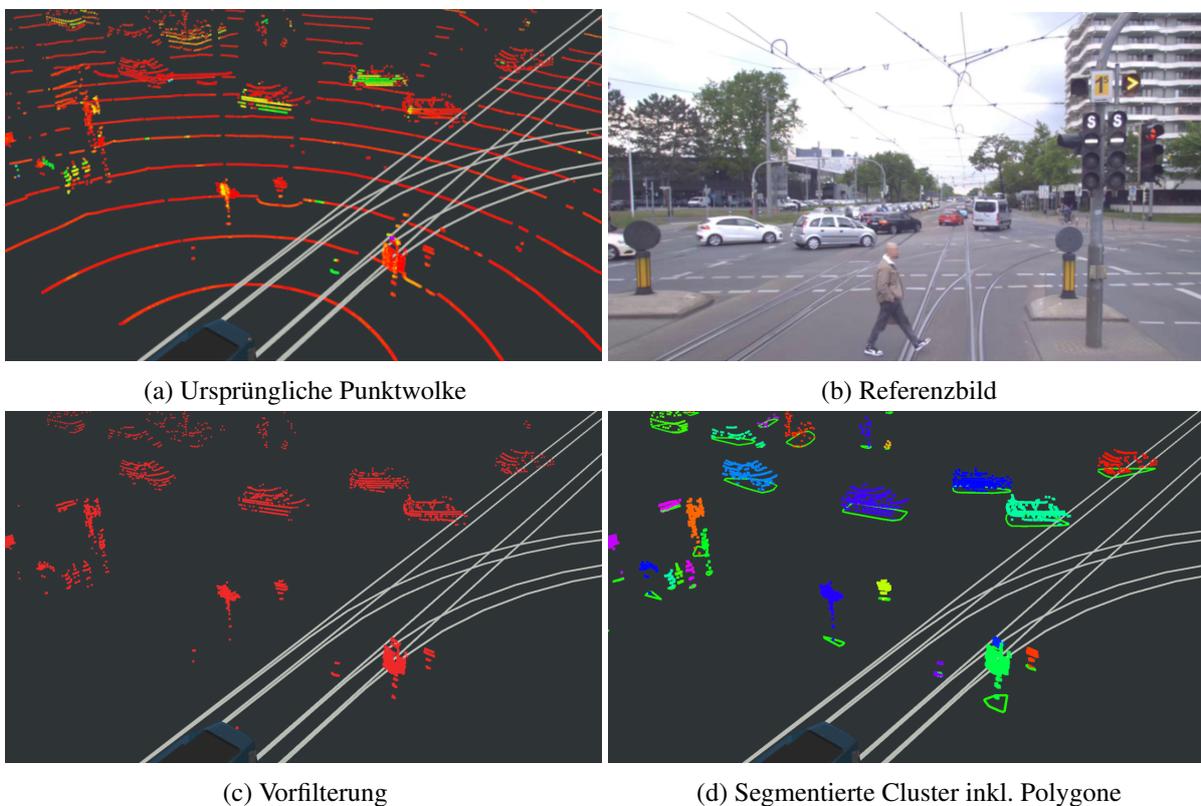


Abbildung 4-13: Beispielszene Lidar Clustering für den auf dem Dach verbauten Lidarsensor Velodyne VLP-32C. Die 3D Darstellungen entsprechen der Vogelperspektive von schräg oben. Der in — dargestellte Gleisverlauf dient nur der Visualisierung und basiert auf der Karte.

#### 4.4.4 2D Objektdetektor in Kamerabildern

Entsprechend der konkretisierten Referenzarchitektur erfolgt die Objektdetektion im Kamerabild als 2D Information innerhalb der Bildebene, welche im Rahmen der *High-Level-Fusion* ausschließlich zur Klassifikation bereits getrackter 3D Objekte erfolgt. Aufgrund der öffentlichen Verfügbarkeit, dem einfachen Training mit eigenen Daten und der guten Performance wird im Rahmen der Referenzimplementierung YOLOv5 eingesetzt.<sup>156</sup> Bei YOLOv5 handelt es sich um eine von Ultralytics Inc. vorangetriebene Weiterentwicklung des 2015 erschienen einstufigen Detektors YOLO (*You Only Look Once*) von Redmon et al.<sup>157</sup> Die YOLOv5 Netze sind auf dem COCO Datensatz<sup>158</sup> mit 80 Klassen vortrainiert, der nicht auf verkehrsspezifischen Daten, sondern auf breit gestreuten Bildern beruht. Zur Adaption im Kontext des automatisierten Fahrens von Straßenbahnen wurde im Rahmen einer Voruntersuchung<sup>159</sup> zur Steigerung der Erkennungsleistung die Anzahl der Klassen auf sechs reduziert und dabei die Klasse *ÖPNV* neu eingeführt. Die sechs Klassen sind nachfolgend in Tabelle 4-4 zusammengefasst:

Tabelle 4-4: Klassenübersicht Kamera 2D Detektion.

Klasse	Beschreibung
<i>Personen</i>	Umfasst alle Fußgänger, wartende Fahrgäste etc.
<i>Fahrrad</i>	Beinhaltet alle Fahrräder, auch solche die nicht gefahren werden.
<i>Pkw</i>	Alle Kraftfahrzeug bis 7,5 t.
<i>Lkw</i>	Alle Fahrzeuge über 7,5 t, die kein Bus und keine Straßenbahn sind.
<i>Motorrad</i>	Beinhaltet alle Motorräder, auch solche die nicht gefahren werden.
<i>ÖPNV</i>	Da es weder in COCO noch in anderen öffentlich verfügbaren Datensätzen zum automatisierten Fahren Straßenbahnen gibt und das Annotieren in großer Zahl den Umfang dieser Arbeit übersteigt, wurde eine neue gemeinsame Klasse <i>ÖPNV</i> geschaffen. Diese fasst als Kompromiss aufgrund der ähnlichen Merkmale (Fenster, Geometrie, Orte des Auftretens im Bild) Busse und Straßenbahnen zusammen.

Zur Reduzierung der Komplexität erfolgt die Auswertung der in der Versuchsbahn verbauten drei Nahsichtkameras mit Fischaugenobjektiven mit dem gleichen Netz wie für die beiden Hauptkameras der Fernsicht. Durch die Verzeichnung der Fischaugenobjektive führt diese Zusammenfassung im Vergleich zu einem zusätzlichen spezialisierten Netz zu einer reduzierten

156 Jocher, G. et al.: ultralytics/yolov5 (2022).

157 Redmon, J. et al.: You Only Look Once (2016).

158 Lin, T.-Y. et al.: Microsoft COCO (2015).

159 Pech, D.: Trainingsstrategie für automatisiertes Fahren (2021).

Erkennungsleistung. Da die Kameras jedoch nur zur Klassifikation bereits getrackter Objekte verwendet werden und der Grad des Einflusses a-priori nicht bekannt ist, wird der Einfluss der unterschiedlichen Verzeichnungen für diese erste Umsetzung nicht weiter betrachtet. YOLOv5 wird als vortrainiertes Netz in fünf verschiedenen Größen unter Abwägung von Rechenaufwand und Detektionsgüte angeboten. Für diese erste Implementierung wird die mittlere Größe YOLOv5m als Kompromiss für eine ausreichend schnelle Auswertung der Daten gewählt.

Zur Adaption des auf COCO vortrainierten unspezifischen Netzes zu den oben genannten Klassen und zur Anpassung an die Umgebung sowie der eingesetzten Kameras wird ein Netz basierend auf folgender Strategie trainiert:<sup>159</sup>

1. Das Netz wird auf den 93.000 Bildern des nuScenes<sup>160</sup> Datensatzes für automatisiertes Fahren trainiert. Hierdurch erlernt das Netz 23 typische Objekte des Straßenverkehrs sowie implizit deren Merkmale zur Erkennung.
2. Für den zweiten Schritt sind 412 Bilder der Fernsichtkameras der Versuchsbahn mit den oben genannten sechs Klassen manuell annotiert. Das aus dem ersten Schritt vortrainierte Netz wird anhand dieser Bilder für die Erkennung der sechs Klassen sowie der eingesetzten Kameras angepasst. Das Training erfolgt aufgrund der geringen Anzahl an eigens annotierten Bildern unter Einfrieren des sogenannten *Backbones*, um basierend auf dem erfolgten Vortraining und damit erlernten Straßenkontextes eine Feinabstimmung vorzunehmen. Für die in der Versuchsbahn verwendeten Nahsichtkameras mit Fischaugenobjektiven sind aufgrund des damit verbundenen Aufwandes keine zusätzlichen Bilder annotiert.

Die eingesetzte Objektdetektion mit YOLOv5 ist beispielhaft in Abb. 4-14 visualisiert.



(a) Detektionen in der rechten Fernsichtkamera.

(b) Detektionen in der mittleren Nahsichtkamera.

Abbildung 4-14: YOLOv5 Beispielauswertung zwei der fünf Kamerabilder.

<sup>160</sup> Caesar, H. et al.: nuScenes (2020).

### 4.4.5 Fusion

Im Rahmen der *High-Level-Fusion* werden die verschiedenen Objektlisten der Sensoren bzw. der zugehörigen Auswertemethode zeitlich verfolgt und vereinigt. Bereits bekannte und zeitlich verfolgte Objekte werden im Folgenden als  $\mathcal{O}_{\text{track}}$  und Objekte eingehender Objektlisten als  $\mathcal{O}_{\text{det}}$  bezeichnet.

#### Einschränkung von Radar

Die in der Versuchsbahn verbauten Radarsensoren haben in der zur Verfügung stehenden Software keine Objekthypothesen für Straßenbahnen. Eine Voruntersuchung hat ergeben, dass eine entgegenkommende oder vorausfahrende Straßenbahn fälschlicherweise als mehrere Pkw hintereinander detektiert wird, deren Gierwinkel jedoch nicht der realen Straßenbahn entsprechen. Die Gierwinkel der fälschlichen Pkw weichen so stark ab, dass die 2D Boundingboxen bei entgegenkommenden Straßenbahnen in den Ego-Kollisionsraum ragen und somit falsch positive Notbremsungen im Rahmen der Verhaltensplanung verursachen. Dies ist nicht als pauschaler Nachteil der Technologie Radar zu bewerten, sondern als fehlende Komponente der vom Hersteller integrierten Auswertemethode. Die Anpassung dieser wäre als Teil einer kommerziellen Umsetzung möglich. Da jedoch für die eingesetzten Radare (wie bei Radarsensoren üblich) kein Zugriff auf Verarbeitungsstufen vor den Objektlisten besteht, wird Radar im Rahmen der Referenzimplementierung ausschließlich zur Bestimmung der Geschwindigkeit bereits vorhandener  $\mathcal{O}_{\text{track}}$  verwendet. Somit werden  $\mathcal{O}_{\text{track}}$  nur durch die beiden Lidarsensoren erzeugt. Da beim Radar die Geschwindigkeit mittels Dopplereffekt eine direkt messbare Größe darstellt, ist diese deutlich robuster und genauer als Schätzverfahren oder Ableitungen mittels Lidar bestimmter Positionen. Bei der Geschwindigkeitsschätzung anhand mittels Lidar bestimmten Positionen ist in erster Linie nicht die Genauigkeit der einzelnen Punktwolke hinderlich, sondern die Ermittlung eines zeitlich verfolgbaren Positionswertes. Wenn bspw. der Flächenschwerpunkt von Boundingboxen oder Polygonen verwendet wird, variieren diese bereits durch eine Ego-Bewegung für stehende Objekte. Aufgrund aller Bewegungen ergeben sich unterschiedliche Reflexionspunkte der Lidare und somit unterschiedliche Flächen sowie Flächenschwerpunkte. Die Zuweisung der von den zwei Radaren gemessenen Geschwindigkeiten erfolgt nach Assoziation (nachfolgend erklärt) der Radar Objekte und der auf Lidar basierenden  $\mathcal{O}_{\text{track}}$ .

#### Modellierung der $\mathcal{O}_{\text{track}}$

Die Fusion und Repräsentation der  $\mathcal{O}_{\text{track}}$  erfolgt in einem frei gewählten ortsfesten ENU Koordinatensystem. Sofern nicht explizit durch einen vorangestellten Index anders gekennzeichnet, beschreiben  $\mathcal{O}_{\text{det}}$  und  $\mathcal{O}_{\text{track}}$  ohne vorangestellten Index die Objekte im ENU. Dies erlaubt die Bewegung der einzelnen  $\mathcal{O}_{\text{track}}$  anhand ihrer jeweiligen Zustandsdaten vorherzusagen. Die Vorhersage der Bewegung wird genutzt, um die Position der  $\mathcal{O}_{\text{track}}$  auf den Zeitpunkt eingehender  $\mathcal{O}_{\text{det}}$  zu schätzen und so im Rahmen der Assoziation falsche oder fehlende Zuweisungen zu reduzieren. Zur Schätzung wird ein sogenanntes *konstantes Geschwindigkeitsmodell* mit dem

Zustandsvektor aus horizontaler Position  $x|y$  und Geschwindigkeit  $\dot{x}|\dot{y}$  im ENU Koordinatensystem mittels Zeitdifferenz  $\Delta t$  zwischen den Zeitpunkten der letzten  $\mathcal{O}_{\text{track}}$  sowie der eingehenden  $\mathcal{O}_{\text{det}}$  extrapoliert. Der Index  $k|k-1$  zeigt dabei an, dass die Zustandsdaten auf den Zeitpunkt  $k$  aus den Daten vom Zeitpunkt  $k-1$  erfolgt:

$$\begin{bmatrix} \hat{x}_{k|k-1} \\ \hat{y}_{k|k-1} \\ \hat{\dot{x}}_{k|k-1} \\ \hat{\dot{y}}_{k|k-1} \end{bmatrix} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \dot{x}_{k-1} \\ \dot{y}_{k-1} \end{bmatrix} \quad (4-3)$$

Durch die Transformation der  ${}_s\mathcal{O}_{\text{det}}$  aus den jeweiligen Sensorkoordinatensystemen in das ortsfeste ENU wird die Eigenbewegung der Straßenbahn hinsichtlich Pose und Geschwindigkeit implizit kompensiert und muss zur Aktualisierung der Zustandsdaten der  $\mathcal{O}_{\text{track}}$  daher nicht weiter berücksichtigt werden. Zur Transformation wird die Ego-Pose anhand der oben beschriebenen Lokalisierung der Straßenbahn mittels GNSS und Odometrie genutzt.

Neben der Position sowie der Geschwindigkeit erhält ein  $\mathcal{O}_{\text{track}}$  zusätzlich eine Klassifikation sowie die bisherige Lebensdauer des Objektes als Eigenschaft.

### Assoziation $\mathcal{O}_{\text{det}}$ zu $\mathcal{O}_{\text{track}}$

Um mit den eingehenden  $\mathcal{O}_{\text{det}}$  bestehende  $\mathcal{O}_{\text{track}}$  zu aktualisieren oder im Fall von eingehenden Lidar-Clustern neue  $\mathcal{O}_{\text{track}}$  zu erzeugen, ist eine Assoziation der Objekte erforderlich. Damit wird geprüft welches  $\mathcal{O}_{\text{det}}$  bereits als  $\mathcal{O}_{\text{track}}$  vorhanden ist. Die Assoziation wird im Rahmen dieser Arbeit entsprechend dem Stand der Technik als Kostenoptimierungsproblem formuliert. In einem ersten Schritt werden die Kosten für die Zuweisung einzelner  $\mathcal{O}_{\text{det}}$  zu einzelnen  $\mathcal{O}_{\text{track}}$  bestimmt. Als erster Schritt wird für jedes  $\mathcal{O}_{\text{det}}$  der quadratische euklidische Abstand<sup>161</sup> zu jedem  $\mathcal{O}_{\text{track}}$  als Kosten berechnet. Im zweiten Schritt werden die globalen Gesamtkosten für die Zuordnung der  $\mathcal{O}_{\text{det}}$  zu  $\mathcal{O}_{\text{track}}$  mittels Kuhn-Munkres-Algorithmus<sup>162</sup> minimiert. Als zusätzliche Lösungseinschränkung sind nachfolgende Bedingungen definiert. Sofern mindestens eine Bedingung erfüllt ist, werden die Kosten für die Zuordnung der zwei Objekte zu  $+\infty$  festgelegt.

- Die Flächenschwerpunkte der Objekte weichen um mehr als 10 m voneinander ab. Einerseits wird hierdurch der Rechenaufwand des Optimierungsproblems reduziert, andererseits werden somit fälschliche Zuordnungen vorgebeugt.

161 Der quadratische euklidische Abstand hat im Vergleich zum euklidischen Abstand den Vorteil, dass der Rechenaufwand durch das Entfallen der Wurzeloperation für vergleichsweise viele Elemente reduziert wird, ohne dabei das Zuordnungsproblem wesentlich zu beeinflussen. Diese und vergleichbare Maßnahmen sind zwecks Echtzeitfähigkeit der Algorithmen getroffen.

162 Munkres, J.: Assignment and Transportation Problems (1957).

- Der Gierwinkel zwischen  $\mathcal{O}_{\text{track}}$  und  $\mathcal{O}_{\text{det}}$  weicht um  $90^\circ$  voneinander ab. Dies verhindert, dass mehrere Objekte, die sich nah beieinander befinden, falsch zugeordnet werden, sollte ein Objekt der  $\mathcal{O}_{\text{track}}$  in den neuen  $\mathcal{O}_{\text{det}}$  fehlen.
- Die Flächen der Objekte weichen um mehr als 50 % ab. Dies verhindert ebenfalls die Zuordnung sollte ein Objekt der  $\mathcal{O}_{\text{track}}$  in den neuen  $\mathcal{O}_{\text{det}}$  fehlen.

### Aktualisierung von $\mathcal{O}_{\text{track}}$ mit Lidar Clustern

Durch das Lösen des Optimierungsproblems ergibt sich eine Zuordnung von  $\mathcal{O}_{\text{det}}$  des Lidar Clusterings zu bestehenden  $\mathcal{O}_{\text{track}}$  sowie je nach Zustand und Messung sowohl  $\mathcal{O}_{\text{track}}$  wie auch  $\mathcal{O}_{\text{det}}$  ohne Assoziationen. Die nicht zugeordneten  $\mathcal{O}_{\text{det}}$  werden nach der Aktualisierung der  $\mathcal{O}_{\text{track}}$  als solche mit einer Geschwindigkeit von 0 km/h sowie der Objektklassifikation *unbekannt* aufgenommen. Die Geschwindigkeit wird, sofern eine Objektdetektion vorhanden, nachfolgend von den eingesetzten Radarsensoren aktualisiert.

$\mathcal{O}_{\text{track}}$  ohne Assoziation werden für einen kurzen Zeitraum beibehalten und mittels oben aufgezeigtem Schätzverfahren aktualisiert. So lassen sich kurzzeitige Verschattungen oder falsch negative Objektdetektionen überbrücken. Je länger der Zustand eines  $\mathcal{O}_{\text{track}}$  jedoch nur geschätzt wird, desto größer ist die Wahrscheinlichkeit für falsch positive Bremsungen. Einerseits können diese durch zu langes Festhalten an einem ursprünglich fälschlicherweise erzeugten  $\mathcal{O}_{\text{track}}$  aus einem falsch positiven  $\mathcal{O}_{\text{det}}$  (also ein Objekt welches in der Realität nicht existiert) ausgelöst werden. Andererseits kann die Position eines  $\mathcal{O}_{\text{track}}$  durch die Schätzung zu weit von der Realität abweichen und so auch bei korrekter Detektion nicht mehr mit dem zugehörigen  $\mathcal{O}_{\text{det}}$  assoziiert werden. Aus diesem Grund werden  $\mathcal{O}_{\text{track}}$  nach 500 ms ohne Assoziation gelöscht. In dieser Zeit hätte das Objekt vom eingesetzten Velodyne VLP-32C 5-mal und vom Ibeo Scala 12-mal erfasst werden können.

Die im Lidar-Clustering aufgezeigten Polygone bestimmten die Position der Objekte. Für die assoziierten  $\mathcal{O}_{\text{track}}$  werden deren bestehende Polygone durch die eingehenden Polygone der jeweils assoziierten  $\mathcal{O}_{\text{det}}$  ersetzt und so die Position der Objekte aktualisiert. Bereits zuvor bestimmte Geschwindigkeiten aus Radar oder eine nachfolgend beschriebene Objektklassifikation aus der Kameradetektion bleiben als Eigenschaft des  $\mathcal{O}_{\text{track}}$  erhalten.

### Aktualisierung von $\mathcal{O}_{\text{track}}$ mit Radar Geschwindigkeiten

Nach der Assoziation von Objekten der Radare mit den bestehenden  $\mathcal{O}_{\text{track}}$  werden die Geschwindigkeiten der  $\mathcal{O}_{\text{track}}$  durch die der Radarmessung ersetzt. Die Zuweisung erfolgt ohne weitere Filterung, da auf den Radarsensoren bereits ein Kalman-Filter für ein Tracking auf dem Sensor eingesetzt wird. Nicht assoziierte Objekte der Radare werden nicht zu neuen  $\mathcal{O}_{\text{track}}$ .

## Klassifikation mittels Kamera

Zur Klassifikation der  $\mathcal{O}_{\text{track}}$  wird für jedes  $\mathcal{O}_{\text{track}}$  ein Ringspeicher mit 50 Einträgen verwendet. Dies entspricht aufgrund der Kamerafrequenz von 10 Hz einer Zeitspanne von 5 s Beobachtung durch eine einzige Kamera. Durch eine mit der Klassenwahrscheinlichkeit der Bildauswertung gewichtete Mehrheitswahl wird die wahrscheinlichste Klasse des  $\mathcal{O}_{\text{track}}$  bestimmt, dazu muss der Ringspeicher nicht vollständig gefüllt sein. Durch den Ringspeicher und den Wahlmechanismus wird die Überbrückung kurzzeitig fehlender Detektionen sowie fehlerhafte Zuweisungen erlaubt.

Die fünf Kameras liefern mit dem YOLOv5 Detektor 2D Objektlisten. Für jede in Pixelkoordinaten beschriebene Objektliste im Koordinatensystem des Bildes  ${}_B\mathcal{O}_{\text{det}}$  werden die 3D-Positionen der  $\mathcal{O}_{\text{track}}$  als 2D Punkte in die Bildebene projiziert. Dazu werden sie anhand der Ego-Pose aus der Lokalisierung in das Kamerakoordinatensystem transformiert und mittels a-priori bestimmter intrinsischer Kalibration der Kameras in Bildkoordinaten umgerechnet. Fällt eine somit bestimmte 2D Position (Pixelkoordinaten) eines  $\mathcal{O}_{\text{track}}$  in die 2D Boundingbox der Bilddetektion, wird die Klassifikation dem Ringspeicher hinzugefügt. Tritt das Objekt in mehreren Kameras gleichzeitig auf, werden alle Elemente dem Ringspeicher hinzugefügt.

### 4.4.6 Zustandserfassung vorfahrtsregelnder Lichtsignalanlagen

Wie in der konkretisierten Referenzarchitektur beschrieben, beruht die Zustandserfassung der LSA auf der Kombination von Kartendaten sowie einer Bildauswertung der Kameras.

#### Auswahl der LSA

Basierend auf dem gegebenen Fahrauftrag sind die zu befahrenden Gleissegmente der Karte und somit die auf diese Segmente referenzierten LSA bekannt. An Weichen existieren meist vorfahrtsregelnde LSA für die unterschiedlichen Fahrtrichtungen. Die Auswahl erfolgt ebenfalls anhand der in der Karte hinterlegten gültigen Fahrtrichtung sowie dem Fahrauftrag. Somit ergeben sich für einen gegebenen Fahrauftrag die während der Fahrt *zu betrachtenden* LSA.

Während der Erfüllung des Fahrauftrages ist aus diesen *zu betrachtenden* LSA die für das vorherrschende Szenario jeweils gültige LSA auszuwählen und mittels Kamera der Signalzustand zu erfassen. Für die Entscheidung, ob eine LSA *zu betrachten* ist, wird das Unterschreiten einer kritischen Distanz  $d_{\text{LSA,rel}}$  entlang der Schiene bis zur Vorbeifahrt der LSA gewählt. Für die Umsetzung im Rahmen der Referenzimplementierung wird diese Distanz als erste Schätzgröße auf den Anhalteweg mit einer geringen Bremsung ausgehend von der Streckenhöchstgeschwindigkeit bestimmt. Zusätzlich ist ein minimaler Abstand von 30 m festgelegt, bei dem die LSA in jedem Fall als *zu betrachten* gilt:

$$d_{\text{LSA,rel}} = \max \left( 30 \text{ m}, \frac{v_{\text{max, LSA}}^2}{2 \cdot 1,5 \text{ m/s}^2} \right) \quad (4-4)$$

Ob auf eine *zu betrachtende* LSA auch *zu reagieren* ist, wird in der nachfolgend beschriebenen Verhaltensplanung festgelegt. Auch bei ausbleibender Detektion des Signalzustandes — bspw. durch Verdeckungen oder Detektionsfehler — wird der Verhaltensplaner somit kartenbasiert über die Annäherung an eine LSA informiert. Im Gegensatz zur rein kamerabasierten Zustandserfassung von LSA ermöglicht die zusätzliche Karteninformation eine Reaktion auch für LSA, deren Zustand bzw. Existenz, aufgrund einer unzureichenden Bildauswertung, nicht bekannt ist.

### **Detektion im Kamerabild**

Bei Annäherung an die LSA wird in einem ersten Schritt eine der fünf Kameras zur Auswertung ausgewählt. Dazu wird die LSA basierend auf den Kartendaten, der Ego-Lokalisierung sowie den a-priori bestimmten intrinsischen Kamerakalibrationen in alle Bildebenen projiziert. Als Bewertungsmaß wird für jede Kamera der Abstand der projizierten LSA zum Bildmittelpunkt sowie die Überprüfung, ob die LSA im Sichtfeld der Kamera liegt, verwendet. Solange die LSA im sichtbaren Bereich einer der beiden Fernsichtkameras liegt, wird aufgrund deren geringer Verzeichnung und damit robusteren Erkennungsleistung eine Fernsichtkamera verwendet. Ist die LSA außerhalb des Sichtwinkels der beiden Fernsichtkameras, wird das Bild einer Nahsichtkamera ausgewählt, in der die LSA möglichst mittig ist. Durch die Abweichung von der Mitte als Bewertungsmaß wird der Einfluss der Verzeichnung der Fischaugenobjektive der Nahsichtkamera reduziert sowie die Robustheit gegenüber Projektionsfehlern erhöht.

Die Projektion erfolgt unter Abschätzung der oberen linken sowie der unteren rechten Ecke der LSA. Diese bestimmen sich aus dem in der Karte hinterlegten Positionswert sowie der Anzahl möglicher Signale und einer damit verbundenen Abschätzung der Breite und Höhe der LSA. Anhand der beiden projizierten Punkte wird eine in der maschinellen Bildauswertung genannte *Region of Interest* (ROI) gebildet, also ein rechteckiger Bereich innerhalb des Bildes in dem die LSA enthalten ist. Anstatt auf dem gesamten Bild mittels Detektor den Zustand der LSA zu ermitteln, wird somit die Robustheit erhöht, da die Detektion auf einen kleineren Bereich beschränkt wird. Dem Detektor werden somit weniger Elemente des Bildes zur Auswertung gegeben, die fälschlicherweise mit den Signalen der LSA verwechselt werden können. Bspw. haben Versuche gezeigt, dass beleuchtete Fenster auf dunklen Fassaden für Detektoren ähnliche Merkmale bilden wie die rechteckigen Signale auf den dunklen Schirmen der LSA. Somit wird die Konfidenz erhöht, da der detektierte Signalzustand tatsächlich der erwarteten LSA zugeordnet werden kann. Da die Projektion aufgrund von Mess-, Kalibrations- sowie Lokalisierungsfehler (insbesondere Gierwinkel) ungenau sein kann, wird die ROI um 150 % der Größe eines einzigen Signalfeldes in der Breite und 100 % in der Höhe erweitert. Ebenfalls werden unmittelbar benachbarte ÖPNV LSA zur Vergrößerung der ROI berücksichtigt, um Fehlinterpretationen der relevanten LSA durch Verwechslungen zu vermeiden. Das Vorgehen und beide ROI sind nachfolgend beispielhaft in Abb. 4-15 a-b dargestellt.

Die Detektion innerhalb der erweiterten ROI erfolgt erneut mit dem YOLOv5m<sup>156</sup> Detektor. Dafür sind in 2575 Bildern die einzelnen Signalfelder der für Straßenbahnen gültigen LSA hän-

disch annotiert sowie nachfolgende Detektionsklassen entsprechend der Signale nach BOStrab definiert: **F 0**, **F 1**, **F 2**, **F 3**, **F 4**, **F 5** sowie **ausgeschaltet**. Dabei werden im Rahmen der Referenzimplementierung nur Signale entsprechend der Verhaltensanforderung berücksichtigt. Die im ÖPNV bspw. häufig genutzten Signale *S* als Bestätigung für den Fahrer über die Signalanforderung oder die Abfertigungssignale *A 1*, *A 2* zum empfohlenen Abfahrtszeitpunkt an Haltestellen werden nicht betrachtet. Der Detektor ist basierend auf den mittels COCO<sup>158</sup> vortrainierten YOLOv5m Netz mit den annotierten Bildern trainiert.

Auf die Annotation der Bedeutung der ganzen LSA anstelle der einzelnen Signalfelder wurde verzichtet, da aufgrund der Variationen im Lichtsignalanlagenaufbau deutlich mehr Bilder hätten annotiert werden müssen.

In Abb. 4-15 ist die Detektion im Kamerabild für eine Beispielszene dargestellt. Im Rahmen des Fahrauftrages soll nach rechts abgebogen werden, weshalb anhand der Karte die rechte LSA ausgewählt wird.

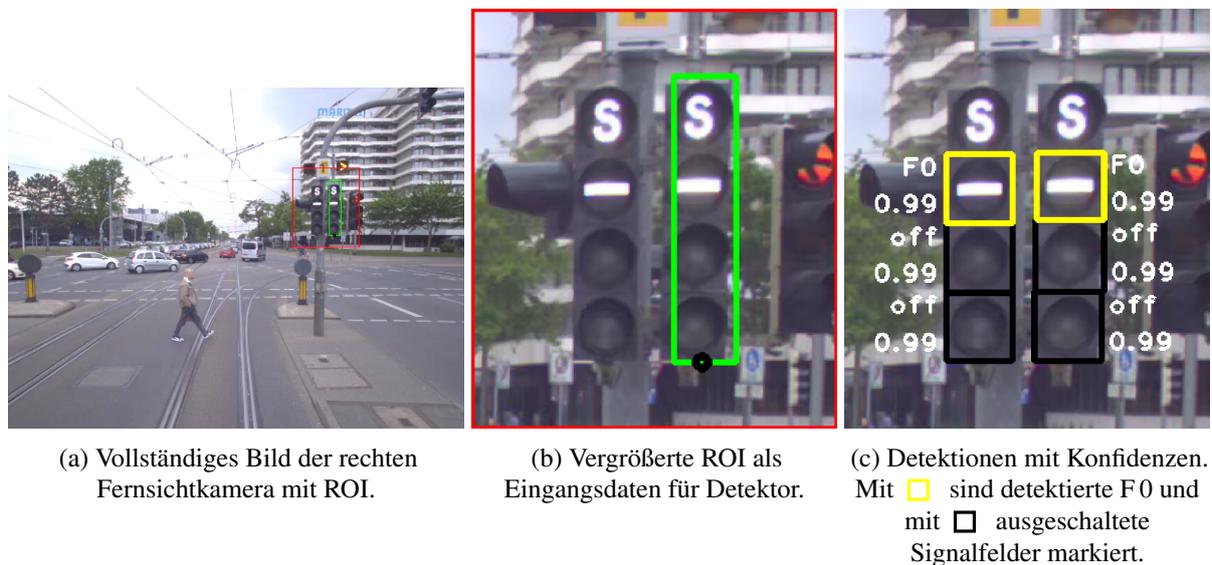


Abbildung 4-15: Beispielszene Zustandserfassung LSA.   exakt projizierte ROI;   erweiterte ROI unter Berücksichtigung der Unsicherheiten und benachbarten LSA.

## Tracking des Zustandes

Für eine eindeutige Zustandsbeschreibung sind die detektierten Signalfelder der relevanten LSA zuzuordnen und so aus mehreren Detektionen eine gültige Bedeutung für die LSA auszuwerten. Im Falle von mehreren LSA wie im obigen Beispiel werden die Detektionen in Spalten eingeteilt und diese basierend auf den vermessenen Positionen und Nachbarschaftsbeziehungen der LSA zugeordnet. Anschließend erfolgt eine Plausibilisierung der Detektionen mit den für jede LSA in der Karte hinterlegten *möglichen Signalzuständen*. Sofern die Detektionen nicht mit den *möglichen Signalzuständen* übereinstimmen oder widersprüchlich sind — bspw. **F 0** und **F 1** gleichzeitig —, werden alle eingehenden Detektionen verworfen. Mittels Ringspeicher

werden ähnlich der Klassifikation von Objekten die letzten acht Detektionen gespeichert und mittels Mehrheitswahl der mutmaßliche Schaltzustand an die Verhaltensplanung übergeben. Der Ringspeicher ermöglicht kurzzeitige Fehldetektionen zu überbrücken. Im Gegensatz zur Klassifikation von Objekten reduziert dies jedoch auch die Dynamik der Zustandserfassung. So muss nach einem Signalwechsel der neue Zustand mindestens viermal hintereinander detektiert werden. Mit den verwendeten 10 Hz Kamerabildern entspricht dies einer Zeit von mindestens 400 ms und wird im Rahmen der Referenzimplementierung als vertretbar betrachtet. Im Fall von ausbleibenden Detektionen (Verdeckungen, Gegenlicht etc.) wird der letzte bekannte Zustand zur Überbrückung für 1 s beibehalten, danach wird der Zustand als *unbekannt* an die Verhaltensplanung übergeben.

#### 4.4.7 Verhaltensplanung: Berücksichtigung von Hindernissen

Für die Verhaltensplanung sind die getrackten und fusionierten  $\mathcal{O}_{\text{track}}$  der Umgebung hinsichtlich ihrer Kritikalität zu bewerten. In diesem Kontext erfolgt die Feststellung, ob ein umgebendes Objekt als Hindernis einzustufen ist, das eine Reaktion erfordert, oder ob es zum Zeitpunkt der Beobachtung als gegenwärtig irrelevant betrachtet wird.

##### Bestimmung *potenziell kritischer* Objekte

Im Gegensatz zu Kraftfahrzeugen ist der Fahrweg von Straßenbahnen durch das Gleis vorgegeben und zur Beachtung von Hindernissen nicht anpassbar. Daher wird die Position und Verlauf des Gleises als Diskriminator zur Unterscheidung von gewöhnlichen Objekten und Hindernissen genutzt. In einem ersten Schritt sind dafür aus dem Fahrauftrag die zu befahrenden Splines  $\mathcal{S}_{\text{mission}}$  der Karte zu bestimmen. Basierend auf der mittels Lokalisierung bestimmten Position  $s_{\text{ego}}$  auf dem Spline  $\mathcal{S}_{\text{ego}}$  und somit bekannten noch zu fahrenden Segmente werden die zur Bewertung *potenziell kritischer* Objekte zu betrachtenden Splines  $\mathcal{S}_{\mathcal{O}} \subseteq \mathcal{S}_{\text{mission}}$  ausgewählt. Als nachfolgender Schritt wird der horizontale Abstand aller  $\mathcal{O}_{\text{track}}$  zum Gleis bestimmt. Dazu wird für die  $m$  Objekte in  $\mathcal{O}_{\text{track}}$  unter Nutzung des jeweils zugehörigen Polygons  $P(\mathcal{O}_{\text{track}})$  der minimale horizontale Abstand  $d_{\mathcal{S}_{\mathcal{O}}\mathcal{O}_i}$  zu den betrachtenden Splines  $\mathcal{S}_{\mathcal{O}}$  als numerisches Optimierungsproblem bestimmt. Der Abstand wird nur in der Horizontalen bestimmt, da einerseits aufgrund der vertikalen Lidar Detektionslücken durch die endlichen Ebenen und FoV insbesondere die Elevation von Objekten nur ungenau bestimmt werden kann, andererseits die Polygone die Kontur von Objekten nur als 2D Fläche in der Horizontalen beschreiben.

$$d_{\mathcal{S}_{\mathcal{O}}\mathcal{O}_i} = \min(\text{Abstand}(P(\mathcal{O}_{\text{track},i}), \mathcal{S}_{\mathcal{O}}) \mid 1 \leq i \leq m) \quad (4-5)$$

Die Splines  $\mathcal{S}_{\text{mission}}$  sind dazu a-priori einmalig in das gleiche ENU zu transformieren, in welchem die  $\mathcal{O}_{\text{track}}$  erzeugt werden.

Unterschreitet der Abstand  $d_{S_{O_i}}$  eines Objektes zur Gleismitte einen festgelegten Wert  $d_{FS,krit}$ , befindet sich das Objekt innerhalb des Fahrschlauches (FS) und wird als *potenziell kritisch* eingestuft. Für die erste Umsetzung im Rahmen dieser Untersuchung wird der Schwellwert auf die halbe Breite der Versuchsbahn  $d_{FS,krit} = 1,2$  m festgelegt. Zwar lässt sich das Verhalten anderer Kraftfahrzeuge mit entsprechendem Aufwand grundsätzlich akzeptabel vorhersagen,<sup>163</sup> dennoch ist die Einordnung eines *potenziell kritischen* Objektes in ein *zukünftig kritisches* Objekt aufgrund der nicht direkt messbaren Intention<sup>164</sup> der Verkehrsteilnehmer, insbesondere für Fußgänger,<sup>165</sup> auch im Kraftfahrzeugbereich eine große funktionale Herausforderung. Aufgrund der getroffenen Prämisse zur reduzierten Komplexität sowie der besonderen Nähe zu Fußgängern wird im Rahmen der Referenzimplementierung auf eine Vorhersage einer zukünftigen Kreuzung anhand des geschätzten Verhaltens umgebender Objekte und somit auf Erkennung *zukünftig kritischer* Objekte verzichtet.

Jedoch werden die identifizierten *potenziell kritischen* Objekte innerhalb des Fahrschlauches auf bereits kreuzendes Verhalten geprüft, um so falsch positiv ausgelöste Bremsungen zu vermeiden. Zur Bestimmung dieser den Fahrschlauch verlassenden Bewegung sind folgende Bedingungen definiert, die alle erfüllt werden müssen:

- **Geschwindigkeit:** Abhängig von der Objektklasse wird eine querende Mindestgeschwindigkeit sowie eine absolute Maximalgeschwindigkeit entlang des Gleises Richtung Straßenbahn (um diagonales Queren zu ermöglichen) geprüft. Die Parametrisierung ist in Anhang A.1 beschrieben.
- **Time-To-Brake:** Basierend auf Abstand, Relativgeschwindigkeit sowie einer mit guten Bedingungen angenommenen Gefahrenbremsung mit  $-3,0$  m/s<sup>2</sup> wird die Kritikalitätsmetrik  $TTB$  bestimmt. Diese muss positiv sein  $TTB_{-3,0 \text{ m/s}^2} > 0$ , um die Kollision unter Idealbedingungen noch zu vermeiden bzw. die Unfallschwere zu reduzieren.
- **Time-To-Collision:** Basierend auf der Objektausdehnung, der lateralen Position sowie der kreuzenden Geschwindigkeit wird die für den Kreuzungsvorgang voraussichtlich erforderliche Zeit  $t_{Kreuz}$  abgeschätzt. Diese muss kleiner sein als die mittels Abstand und Relativgeschwindigkeit bestimmte Zeit, die bis zu einer potenziellen Kollision vergeht:  $t_{Kreuz} < TTC$ .

Zur Vermeidung von falsch positiven Bremsungen wird zusätzlich die Bedingung eingeführt, dass die *potenziell kritischen* Objekte mindestens 0,1 m hoch sein müssen. Dies verhindert ungewollte Bremsungen für kleinere Objekte wie zwischen den Gleisen liegende Steine oder Äste sowie auch für falsch positive Phantomobjekte bspw. ein Versagen des Bodenfilters im Rahmen des Lidar-Clustering. Die 0,1 m sind als konservative Abschätzung dieser ersten Umsetzung gewählt,

---

163 Mori, K. et al.: Perception Relevance (2023).

164 Hubmann, C. et al.: Automated Driving in Uncertain Environments (2018), S. 1.

165 Yang, B. et al.: Crossing or Not? (2022), S. 5338.

um unbekannte Objekte (bspw. verlorene Gegenstände) in dieser Größenordnung bezüglich einer Bremsung zu berücksichtigen. Dabei muss beachtet werden, dass aufgrund der vertikalen Ebenen eines Lidarsensors und der damit verbundenen Detektionslücken in der Vertikalen, die Höhe eines realen Objektes, insbesondere im Randbereich des FoV, vom Lidarsensor unterschätzt werden kann. Gleichzeitig hat dieses Filter jedoch den Nachteil, dass im Fall des Auftretens von noch kleineren, jedoch kritischen Objekten wie z. B. flache Gegenstände auf den Gleisen, für die ein Fahrer gebremst hätte, nicht berücksichtigt werden.

### Sollverhalten für *potenziell kritische* Objekte

Für jedes der verbleibenden *potenziell kritischen* Objekte wird ein Sollverhalten bestimmt. Dieses wird im Rahmen der Referenzimplementierung entweder als Folgeregelung ähnlich *Adaptive Cruise Control* (ACC)<sup>166a</sup> oder einer Halterege lung bezüglich eines Haltepunktes vor dem Objekt umgesetzt. Die Entscheidung für die Umsetzung als Folgeregelung oder Halterege lung erfolgt anhand der Geschwindigkeit des Objektes tangential zur Schiene.

**Halterege lung**  $v_{O,tang} \leq 0$ : Für alle stationären oder innerhalb des Fahrschlauches sich auf die Straßenbahn bewegend en Objekte wird eine Halterege lung umgesetzt. Das Bremsverhalten der Straßenbahn wird dabei als gleichförmig beschleunigte Bewegung modelliert. Ragt das Objekt wie nachfolgend in Abb. 4-16 gezeigt nur teilweise in den Fahrschlauch, wird als zugrunde liegender Abstand zwischen Objekt und Bahn nicht der zur Bahn nächste Punkt des Objektes im Fahrschlauch, sondern der generell zur Bahn nächste Punkt des Objektes entlang des Gleises als konservative Abschätzung genutzt. Neben diesem Abstand  $d_{ego,O}$  wird zusätzlich ein Halteabstand  $d_{halt} = 3,0$  m berücksichtigt, um vor stehenden Objekten anzuhalten.<sup>167</sup>

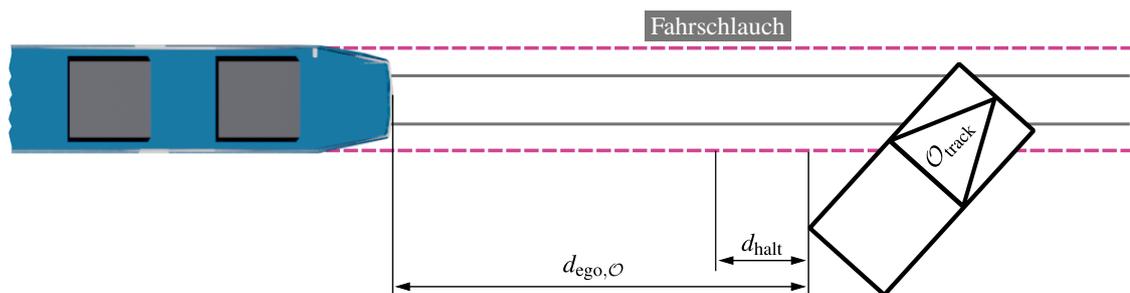


Abbildung 4-16: Bestimmung des zur Regelung genutzten Abstandes von Objekten die in den Fahrschlauch ragen.

Anstatt nur die abzubauen e Ego-Geschwindigkeit der Bahn zu betrachten, wird davon ausgegangen, dass gegebenenfalls entgegenkommende Objekte mit mindestens der gleichen

166 Winner, H. et al.: Handbuch Fahrerassistenzsysteme (2015) a: S 851 ff., b: S. 874.

167 Eine empirische Betrachtung von Haltevorgängen der menschlichen Fahrer hat eine starke Streuung von etwa 0,8 m bis über 8,0 m Abstand zu stehenden Hindernissen ergeben. Aus diesem Grund wurde für die erste Umsetzung 3,0 m als Optimierungsparameter gewählt.

Verzögerung wie die Bahn abbremsen, weshalb als generischer Ansatz die Relativgeschwindigkeit entlang des Gleises  $v_{\text{rel,tang}}$  für die Bestimmung des Sollverhalten  $a_{\text{soll}}$  berücksichtigt wird.

$$a_{\text{soll},\mathcal{O}} = -\frac{1}{2} \cdot \frac{v_{\text{rel,tang}}^2}{d_{\text{ego},\mathcal{O}} - d_{\text{halt}}} \quad (4-6)$$

Zur Bewertung der Kritikalität ist bisher nur der laterale Gleisabstand berücksichtigt. Mit Formel 4-6 wird somit auch die Sollverzögerung für kleine Ego-Geschwindigkeiten und noch weit entfernte Objekte bestimmt. Um zu kleine Bremsreaktionen auf (noch) nicht relevante Objekte zu vermeiden, wird zusätzlich die Bedingung einer leichten Bremsung  $a_{\text{soll}} < -1 \text{ m/s}^2$  eingeführt und Objekte sowie zugehörige Sollbeschleunigungen mit zu kleiner Reaktion verworfen.

**Folgeregelung**  $v_{\mathcal{O},\text{tang}} > 0$ : Für alle Objekte, die sich mit der Fahrtrichtung der Bahn bewegen, wird eine auf Zeitlücken  $\tau_d$ ,  $\tau_v$  sowie  $\tau_{\text{soll}}$  basierende Folgeregung entsprechend der aus dem Kraftfahrzeugbereich<sup>166b</sup> bekannten ACC Regelung modelliert. Die zugehörige Parametrierung ist in Anhang A.2 zusammengefasst.

$$a_{\text{soll},\mathcal{O}} = \frac{v_{\text{rel,tang}}^2 + (d_{\text{soll},\mathcal{O}} - d_{\text{ego},\mathcal{O}}) / \tau_d}{\tau_v} \quad (4-7)$$

$$d_{\text{soll},\mathcal{O}} = v_{\text{ego,tang}} \cdot \tau_{\text{soll}}$$

Mit dem aus der Folgeregung bestimmten Verhalten  $a_{\text{soll}}$  wird dem Verhalten des vorausfahrenden Fahrzeuges entsprechend der Zeitkonstanten gefiltert gefolgt. Abweichungen im geschwindigkeitsabhängigen Soll-Abstand  $d_{\text{soll}}$  werden entsprechend der Dynamik von  $\tau_d$  berücksichtigt. Zusätzlich erfolgt für Objekte mit  $v_{\mathcal{O},\text{tang}} > 0$  die Bestimmung einer  $TTB_{-3,0 \text{ m/s}^2}$ . Sobald diese kleiner 0 ist, wird unter Umgehung der endlichen Dynamik der ACC Regelung eine maximale Gefahrenbremsung mit idealisierten  $a_{\text{soll}} = -4,0 \text{ m/s}^2$  eingeleitet.<sup>168</sup>

Abschließend wird das kritischste Sollverhalten aller *potenziell kritischen* Objekte als Sollverhalten für das Modul zur Berücksichtigung von Hindernissen bestimmt, indem die minimale aller durch Objekte hervorgerufenen Sollbeschleunigungen  $a_{\text{soll}}$  ausgewählt wird.

#### 4.4.8 Verhaltensplanung: Halt an Lichtsignalanlagen

Das Modul zur Zustandserfassung der LSA gibt die Entfernung sowie das angezeigte Signal bzw. im Fall ohne Detektion die Information über einen unbekanntem Signalzustand an die Verhaltensplanung weiter. Zeigt die LSA ein Fahrt freigebendes Signal F 1-F 3, wird sie nicht weiter berücksichtigt und kein einschränkendes Sollverhalten bestimmt. Für das Signal F 5,

<sup>168</sup> Dieser Wert ist in der Realität aufgrund der gegebenen Reibwerte quasi nicht zu erreichen.

welches Abbiegen unter Berücksichtigung von Gegenverkehr erlaubt, wird der Fahrschlauch im Kreuzungsbereich auf Abwesenheit aller *potenziell kritischen* Objekte geprüft. Ist der Fahrschlauch frei, wird die LSA ebenfalls nicht weiter berücksichtigt. Zeigt die LSA ein *Halt zu erwartendes* Signal F4, wird dieses im Rahmen der Referenzimplementierung wie ein Fahrt freigebendes Signal nicht weiter berücksichtigt. Da bei F4 je nach Ego-Geschwindigkeit und Abstand sowohl ein Halt wie auch die Weiterfahrt als korrektes Verhalten gültig sind und die menschlichen Fahrer sich nicht deterministisch verhalten werden, sind für die Anwendung von *Silent Testing* Abweichungen zu erwarten. Auf eine komplexere Verhaltensplanung für F4 wird zunächst verzichtet. Zeigt die LSA ein Halt zeigendes Signal F0 oder ist der Signalzustand unbekannt, wird ein Sollverhalten zur Halteregeleung bestimmt. Dazu wird entsprechend Formel 4-6 der Objektdetektion der Haltevorgang ebenfalls als gleichförmig beschleunigte Bewegung zum Abbau von  $v_{ego}$  modelliert, wobei als Abstand zur LSA der in der Karte hinterlegte zugehörige Haltepunkt gewählt wird.

$$a_{soll,LSA} = -\frac{1}{2} \cdot \frac{v_{ego}^2}{d_{ego,LSA}} \quad (4-8)$$

Um ebenfalls zu kleine Reaktionen zu vermeiden sowie auch ein Wiederanfahen bspw. nach Berücksichtigung langsamer Fahrt oder Stillstand als Folge eines vorherigen Hindernisses zu ermöglichen, sind ebenfalls folgende Mindestverzögerungen definiert:

- **Zustand F0:** Eine Analyse des menschlichen Verhaltens hat gezeigt, dass Straßenbahnfahrer häufig früh auf F0 reagieren und teilweise vergleichsweise langsam auf die LSA zurollen. Aus diesem Grund wird bereits die sehr leichte Bremsung mit  $-0,5 \text{ m/s}^2$  als Mindestverzögerungen gewählt. Um darüber hinaus ungewolltes Wiederanfahen zu vermeiden, wird unter 5,0 m Abstand zur LSA  $a_{soll}$  in jedem Fall berücksichtigt. Diese beiden Bedingungen für den Zustand F0 sind in folgender Gleichung 4-9 zusammengefasst:

$$a_{soll,LSA} < -0,5 \text{ m/s}^2 \quad \vee \quad d_{ego,LSA} < 5,0 \text{ m} \quad (4-9)$$

- **Zustand unbekannt:** Um falsch positive Bremsungen für unbekannt Zustände zu vermeiden, jedoch nicht versehentlich ein Halt zeigendes Signal zu überfahren, wird für unbekannt Signalzustände eine stärkere Bremsung mit  $-2,0 \text{ m/s}^2$  gewählt. Durch die stärkere und damit spätere Bremsung soll durch die Annäherung der reale Signalzustand möglichst noch erfasst werden. In gleicher Weise zu F0 wird ebenfalls ein Mindestabstand von 5,0 m zur LSA berücksichtigt, ab dem in jedem Fall gebremst wird. Diese beiden Bedingungen für den unbekannt Zustand sind in folgender Gleichung 4-10 zusammengefasst:

$$a_{soll,LSA} < -2,0 \text{ m/s}^2 \quad \vee \quad d_{ego,LSA} < 5,0 \text{ m} \quad (4-10)$$

#### 4.4.9 Verhaltensplanung: Halt an Haltestellen

Die zu beachtenden Haltestellen sind durch den Fahrauftrag gegeben. Durch die mittels Lokalisierung bekannte Ego-Position sowie die Positionen der Haltestellen mit der Referenzierung auf die Gleis-Splines, ist der Abstand  $d_{\text{ego,HS}}$  zur nächsten Haltestelle bekannt. Entsprechend der Verhaltensplanung zu LSA wird ein Sollverhalten zur Halteregelelung bestimmt. Dazu wird entsprechend Formel 4-6 der Haltevorgang ebenfalls als gleichförmig beschleunigte Bewegung zum Abbau von  $v_{\text{ego}}$  modelliert, wobei als Abstand  $d_{\text{ego,HS}}$  gewählt wird. Für einen komfortablen Halt wird die Verzögerung für Haltestellen ähnlich zu LSA ab  $-0,5 \text{ m/s}^2$  beachtet:

$$a_{\text{soll,HS}} < -0,5 \text{ m/s}^2 \quad (4-11)$$

Die Voruntersuchung zur Parametrisierung von  $a_{\text{krit}}$  in Kapitel 3.3.3 hat jedoch gezeigt, dass in den meisten Fällen bei höheren Geschwindigkeiten die menschlichen Fahrer bereits weit vor der Haltestelle mit einer Verzögerung von  $a_{\text{Fahrer}} \approx 0 \text{ m/s}^2$  auf diese zurollen. Zur Nachahmung dieses Fahrverhaltens und Vorbeugung falsch positiver Abweichungen wird folgende zusätzliche Bedingung eingeführt, die sich nur auf Geschwindigkeiten  $> 10 \text{ m/s}$  bezieht und nur dann aktiv ist, wenn innerhalb der nächsten 10 s für die Haltestelle gebremst werden soll:

$$a_{\text{soll,HS}} = \begin{cases} -\frac{1}{2} \cdot \frac{v_{\text{ego}}^2}{d_{\text{ego,HS}}}, & a_{\text{soll,HS}} < -0,5 \text{ m/s}^2 \\ 0 \text{ m/s}^2, & v_{\text{ego}} > 10 \text{ m/s} \wedge TTB_{-0,5 \text{ m/s}^2} < 10 \text{ s} \\ \text{nicht aktiv,} & \text{sonst} \end{cases} \quad (4-12)$$

Wie in Kapitel 4.3 zur Konkretisierung der Referenzarchitektur beschrieben, ist die Steuerung und Überwachung des Fahrgastwechsels nicht Teil dieser Untersuchung und wird daher nicht weiter berücksichtigt. Für die Anwendung von *Silent Testing* wird das Wiederauffahren des menschlichen Fahrers an jeder Haltestelle als Endzeitpunkt der Haltephase a priori für jede Messung bestimmt. Bei Überschreiten des Endzeitpunktes ist  $a_{\text{soll,HS}}$  nicht mehr aktiv.

#### 4.4.10 Verhaltensplanung: Höchstgeschwindigkeit

Im Gegensatz zur Verhaltensplanung bezüglich Hindernissen, LSA und Haltestellen existiert zu jedem Zeitpunkt und Ort eine gültige Höchstgeschwindigkeit. Aus diesem Grund wird im Gegensatz zu allen anderen Kategorien kontinuierlich ein valides  $a_{\text{soll},v_{\text{max}}}$  in Abhängigkeit der Ego-Position bestimmt. So dient nach Abwesenheit des Haltegrundes (Haltestelle, Hindernis oder LSA) die nachfolgend beschriebene Regelung der Höchstgeschwindigkeit auch zum Wiederauffahren.

Auf eine witterungsabhängige Anpassung der Geschwindigkeit zur Anwendung von *Silent Testing* wird wegen des Detektionsaufwandes im Rahmen dieser Arbeit verzichtet. Basierend auf dem Fahrauftrag sowie in der Karte auf die Splines referenzierten Geschwindigkeitsbeschleunigungen ist ähnlich der Haltestellen der Ort und Abstand zur nächsten sowie initial auch zur letzten Geschwindigkeitsbeschränkung bekannt. Für die aktuelle Geschwindigkeitsbeschränkung (Index akt) wird ähnlich der ACC-Folgeregelung mit einer Zeitkonstante von  $\tau_{v_{\max}} = 10$  s die Sollbeschleunigung  $a_{\text{soll},v_{\max,\text{akt}}}$  in Abhängigkeit der Abweichung der Ego-Geschwindigkeit bestimmt.

$$a_{\text{soll},v_{\max,\text{akt}}} = \frac{v_{\max,\text{akt}} - v_{\text{ego}}}{\tau_{v_{\max}}} \quad (4-13)$$

Eine Analyse des menschlichen Fahrverhaltens hat gezeigt, dass der menschliche Fahrer die erlaubte Höchstgeschwindigkeit selten mit einer Beschleunigung außerhalb von  $\pm 1,0$  m/s<sup>2</sup> regelt. Aus diesem Grund wird die Verhaltensplanung zur Höchstgeschwindigkeit und der darin bestimmten Sollbeschleunigung in gleichem Maß beschränkt.

$$-1,0 \text{ m/s}^2 \leq a_{\text{soll},v_{\max,\text{akt}}} \leq 1,0 \text{ m/s}^2 \quad (4-14)$$

Zusätzlich wird für die nachfolgende Geschwindigkeitsbeschränkung (Index flg) geprüft, ob an dieser die Soll-Geschwindigkeit im Vergleich zur aktuellen Vorgabe nach unten beschränkt wird. Falls ja, wird mittels  $TTB_{-1} \text{ m/s}^2 < 0$  geprüft, ab wann eine Bremsung mit  $-1,0$  m/s<sup>2</sup> auf das neue, stärker begrenzende Regelziel erforderlich ist, um noch vor der Vorbeifahrt am zugehörigen Verkehrszeichen der neuen Beschränkung zu entsprechen. Für die Bestimmung der TTB wird die Differenz zwischen Ego-Geschwindigkeit und der nächsten Geschwindigkeitsbeschränkung verwendet sowie der mittels Spline und Lokalisierung bestimmte Abstand. Eine erneute Modellierung als gleichförmig beschleunigte Bewegung ergibt somit:

$$a_{\text{soll},v_{\max,\text{flg}}} = -\frac{1}{2} \cdot \frac{(v_{\max,\text{flg}} - v_{\text{ego}})^2}{d_{\text{ego,flg}}} \quad (4-15)$$

Dabei wird  $a_{\text{soll},v_{\max,\text{flg}}}$  durch die Prüfung mittels TTB auf eine minimale Verzögerung von  $-1,0$  m/s<sup>2</sup> jedoch nicht auf eine maximale Verzögerung wie bei  $v_{\max,\text{akt}}$  beschränkt.

#### 4.4.11 Auswahl des Verhaltens und Berücksichtigung von Streckentrennern

Wie in der Konkretisierung der Referenzarchitektur festgehalten wird aus den oben aufgezeigten einzelnen Verhaltensmodulen mit ihrer jeweiligen  $a_i$  ein Gesamtverhalten  $a_{\text{soll}}$  bestimmt. Zur Priorisierung wird der Stillstand der Straßenbahn als sicherer Zustand und damit das niedrigste

$a_i$  als risikominimales Verhalten betrachtet. Daher wird das Gesamtverhalten  $a_{\text{soll}}$  als Minimum der vier vorgelagerten Module bestimmt.

$$a_{\text{soll}} = \min(a_{\text{soll},\mathcal{O}}, a_{\text{soll},\text{LSA}}, a_{\text{soll},\text{HS}}, a_{\text{soll},v_{\text{max}}}) \quad (4-16)$$

Basierend auf der Karte und der Lokalisierung ist die Position der Streckentrenner bekannt. Sofern  $a_{\text{soll}} > -1,0 \text{ m/s}^2$  und somit für die Planung kein Szenario mit erhöhtem Risiko vorliegt, wird 1 m um den Streckentrenner  $a_{\text{soll}} = 0 \text{ m/s}^2$  überlagert und damit der Fahrstrom kurzzeitig abgeschaltet.

Da im Rahmen dieser Umsetzung kein aktorischer Eingriff erfolgt, gilt entsprechend Kapitel 3 das bestimmte  $a_{\text{soll}}$  als  $a_{\text{OuT}}$  zur Anwendung von *Silent Testing*. Zusätzlich wird das so bestimmte  $a_{\text{OuT}}$  auf  $-4,0 \text{ m/s}^2$  als Untergrenze beschränkt. Dieser Wert ist im mathematischen Sinne kleiner als die maximale Verzögerung einer Gefahrenbremsung unter guten Bedingung. Hierdurch ergibt sich durch den Vergleich mit  $a_{\text{Fahrer}}$  kein fälschlicherweise abweichendes Verhalten, falls sowohl  $a_{\text{Fahrer}}$  als auch  $a_{\text{OuT}}$  sehr stark bremsen, mathematisch das OuT jedoch eine noch stärkere Bremsung anfordert als physikalisch in der Realität abbildbar ist.

Gleichzeitig gilt durch die Kombination der oben aufgezeigten Limitierung der Regelung der Höchstgeschwindigkeit  $a_{\text{soll},v_{\text{max}}}$  auf  $+1,0 \text{ m/s}^2$  sowie einer immer gültigen Höchstgeschwindigkeit und somit auch immer aktiven Regelung, dass das Gesamtverhalten  $a_{\text{OuT}}$  nach 4-16 grundsätzlich mit  $+1,0 \text{ m/s}^2$  nach oben beschränkt ist.

## 5 Anwendung Silent Testing

In diesem Abschnitt wird die in Kapitel 3 entworfene Methode um *Silent Testing* mittels der im vorherigen Kapitel aufgezeigten Referenzimplementierung angewendet. Hierzu werden zunächst die für die Anwendung ausgewählten Daten vorgestellt. Anschließend werden die identifizierten Abweichungen und davon abgeleitete Herausforderungen der Straßenbahnautomatisierung diskutiert.

Für die Anwendung von *Silent Testing* sind zwischen März 2022 und August 2023 mit Unterbrechungen von wenigen Wochen aufgrund von Wartungs- und Reparaturarbeiten mit der Versuchsbahn Daten des alltäglichen Linienbetriebes aufgezeichnet worden. Aufgrund der Erstmaligkeit dieser Durchführung und der damit bereits erwarteten Vielzahl an zu identifizierenden Herausforderungen bei der Automatisierung von Straßenbahnen sowie dem zeitlichen Bedarf zum Übertragen der Daten für eine Auswertung außerhalb des Fahrzeuges, sind keine Nachtfahrten bei vollständiger Dunkelheit (jedoch bei Dämmerung) enthalten. Insgesamt beinhaltet der Datensatz 2.114 Fahrten mit einer Gesamtstrecke von etwa 12.767 km im Darmstädter Straßennetz. Jede Fahrt kennzeichnet sich durch einen Fahrauftrag wie bspw. als Linienbetrieb von einer vorgegebenen Endhaltestelle zu einer anderen zu fahren und dabei einer vorgegebenen Route zu folgen sowie dadurch vorgegebene Haltestellen zu berücksichtigen.

Für die Identifikation von Abweichungen im Rahmen von *Silent Testing* wird entsprechend Kapitel 3.3.2 folgende Bedingung geprüft:

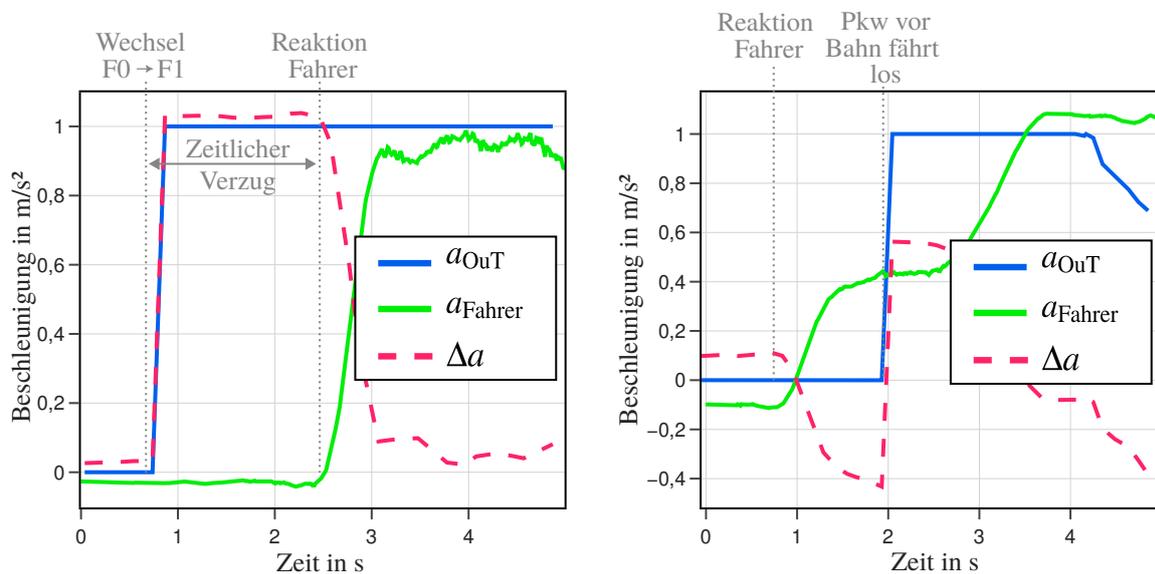
$$|\Delta a| = |a_{\text{OuT}} - a_{\text{Fahrer}}| > a_{\text{krit}} = 2,0 \text{ m/s}^2 \quad (5-1)$$

Aufgrund der zuvor angeführten Limitierung der Verhaltensplanung auf  $+1 \text{ m/s}^2$  zur Regelung der Höchstgeschwindigkeit ist es durch die Bedingung  $|\Delta a| > 2,0 \text{ m/s}^2$  nicht möglich Abweichungen zu identifizieren, die aus dem Stillstand heraus resultieren. Würde das OuT bspw. an einer LSA fälschlicherweise von einem F 1 statt in der Realität tatsächlich gezeigtem F 0 ausgehen, so würde es mit  $a_{\text{OuT}} = 1,0 \text{ m/s}^2$  anfahren. Gleichzeitig bliebe der menschliche Fahrer mit  $a_{\text{Fahrer}} \approx 0,0 \text{ m/s}^2$  stehen. Die Bedingung  $|\Delta a| > 2,0 \text{ m/s}^2$  würde somit nicht erfüllt und die Abweichung nicht identifiziert werden.

Andererseits bei einer korrekten Erkennung der Signalzustände stellt das Anfahren dennoch eine besondere Herausforderung an den Vergleich von OuT mit dem menschlichen Fahrer dar. Aufgrund der unterschiedlichen Reaktionszeiten von Mensch und dem OuT, würde ein Anfahren aus dem Stillstand mit den Bedingungen nach Gleichung 5-1 auch ein niedriger gewähltes  $a_{\text{krit}}$  oft zu falsch positiv identifizierten Abweichungen führen. Wechselt bspw. eine LSA tatsächlich von F 0 auf F 1 und gibt damit die Fahrt frei, wird der menschliche Fahrer in der Regel erst nach

einer kurzen Reaktionszeit Anfahren, während das OuT mutmaßlich schneller reagieren würde. Hinzukommt, dass im Rahmen der Referenzimplementierung beim Anfahren das geforderte Sollverhalten  $a_{\text{OuT}}$  nahezu sprunghaft steigt und die Dynamik des realen Systems und damit mögliche Verzugszeiten durch die Trägheit der Straßenbahn nicht berücksichtigt werden. Ein solcher Wechsel von F0 auf F1 ist nachfolgend in Abb. 5-1 (a) anhand von Realdaten dargestellt.

Eine Überprüfung von  $\Delta a$  mit einer zeitlichen Verschiebung könnte dieses Problem reduzieren, jedoch nicht verhindern. Der Fahrer könnte sich aufgrund einer Vielzahl möglicher Ursachen unterschiedlich verhalten und später anfahren, weil er zum bspw. die LSA kurzzeitig nicht beobachtet. So zeigt Abb. 5-1 (b) als Beispiel für eine frühere Fahrerreaktion das Anfahren nach dem Anhalten hinter zwei Pkw. Der menschliche Fahrer fährt kurz nach dem vorderen Pkw an, obwohl der Pkw, der sich unmittelbar vor der Straßenbahn befindet, noch nicht losgefahren ist. Der menschliche Fahrer antizipiert in dieser Situation, dass der Pkw vor ihm ebenfalls zeitnah Anfahren wird.



(a) Wechsel von F0 auf F1 einer LSA. Der Fahrer reagiert in diesem spezifischem Fall etwa 1,5 s später.

(b) Anfahren hinter zwei stehenden Pkw. Der Fahrer fährt bereits los wenn der 2. Pkw vor der Bahn beginnt zu fahren. Die Automatisierung würde erst Anfahren, wenn der 1. Pkw (unmittelbar vor Bahn) losfährt.

Abbildung 5-1: Schwierigkeiten der Identifikation von Abweichungen aufgrund unterschiedlicher Reaktionszeiten im Beschleunigungsverlauf beim Anfahren.

Aufgrund der Komplexität der Ursachen für unterschiedliche Reaktionszeiten und der damit verbundenen Schwierigkeit, diese zu identifizieren, wird in dieser ersten Anwendung auf eine zeitliche Betrachtung verzichtet. Dies ist auch als besondere Schwäche von *Silent Testing* zu nennen, da so insbesondere das sicherheitsrelevante Anfahren (Fahrschlauch frei von Hindernissen, korrekte Erfassung des Signals etc.) erschwert zu bewerten ist.

Neben der Überprüfung von  $\Delta a$  als Kriterium für abweichendes Verhalten sind weitere nachgelagerte Bedingungen denkbar, jedoch wird aufgrund der erstmaligen Anwendung darauf

verzichtet und identifizierte Abweichungen erst in den nachfolgenden Kapiteln nach Bedarf gefiltert. Hierdurch kann jedoch eine fälschlicherweise viel höhere Zahl an Abweichungen als an tatsächlich zugehörigen Herausforderungen identifiziert werden. Dies ist auf folgende Gründe zurückzuführen:

- Der Grund für die Abweichung ist nicht stabil, sondern ändert sich während der Abweichung. Dies kann bspw. durch eine Unterbrechung der Erkennung einer LSA oder eines Objektes geschehen. Hierdurch wird ein Grund in mehrere Abweichungen geteilt.
- Die Abweichung ist nahe dem Grenzwert  $|\Delta a| \approx 2,0 \text{ m/s}^2$ . Durch wiederholtes Unter- und Überschreiten wird ebenfalls ein Grund in mehrere Abweichungen geteilt wird.

Daher wurde im Rahmen der ersten Anwendung ein Ereignishorizont von 5 s gewählt, innerhalb dessen Abweichungen mit dem vermeintlich selben Grund (gleiche LSA, gleiches Objekt etc.) zusammengefasst werden. Der Grund kann dabei nur als vermeintlich angesehen werden, da er nicht für alle Abweichungen bekannt ist. Wie in Kapitel 3.3.2 aufgezeigt, gilt für  $\Delta a < 0$  also einer stärkeren Bremsung bzw. weniger starken Beschleunigung des OuT, dass durch das aktive Modul der Verhaltensplanung auch der Grund für das Bremsen oder eine geringe Beschleunigung bekannt ist. Hingegen gilt bei  $\Delta a > 0$ , dass der Grund für die restriktivere Handlung des Menschen nicht bekannt ist. Wie in Kapitel 3.3.2 beschrieben, werden Abweichungen mit  $\Delta a < 0$  mit  $\mathcal{A}^-$  bezeichnet, während solche mit  $\Delta a > 0$  als positive Abweichung mit  $\mathcal{A}^+$  bezeichnet werden. Die  $\mathcal{A}^-$  stellen aufgrund des davon ausgehenden defensiveren Verhaltens insbesondere Herausforderungen als Komfort- und Akzeptanzproblem dar, die es für eine erfolgreiche Automatisierung zu lösen gilt. Gleichwohl stellen die  $\mathcal{A}^+$  jedoch ein Sicherheitsproblem dar, da sie auf ein ausgebliebenes und gegebenenfalls erforderliches Verhalten hinweisen.

Durch die Anwendung der beschriebenen *Silent Testing* Methode mittels der Referenzimplementierung aus Kapitel 4.4 sind insgesamt 15.318 Abweichungen  $\mathcal{A}$  identifiziert. Die Verteilung der Abweichungen auf die vier Module zur Verhaltensplanung ist in Tabelle 5-1 dargestellt.

Tabelle 5-1: Identifizierte Abweichungen basierend auf dem zum Zeitpunkt aktiven Modul der Verhaltensplanung.

	<b>Lichtsignal- anlagen</b>	<b>Haltstellen</b>	<b>Höchstgeschwin- digkeit</b>	<b>Objekte</b>
$\mathcal{A}^-$	5.739	1	297	7.925
$\mathcal{A}^+$	0	2	1.335	19

Nachfolgend werden die identifizierten  $\mathcal{A}^-$  entsprechend dem zu dem Zeitpunkt aktiven Modulen der Verhaltensplanung in Unterkapiteln diskutiert. Die Analyse folgt über die Module hinweg einem festen Schema:

- **Makroskopische Betrachtung:** Die Verteilung der Abweichungen wird statistisch betrachtet und wenn möglich unmittelbar verursachende Herausforderungen für die Automatisierung von Straßenbahnen abgeleitet. Für Indizien, die jedoch keine Zuordnung erlauben, werden Hypothesen (als Gegenhypothesen) für die nachfolgende mikroskopische Betrachtung formuliert. Dabei ist einerseits zu beachten, dass diese Hypothesen in erster Linie als Werkzeug zu verstehen sind, um die mikroskopische Betrachtung zu strukturieren und nicht bereits sämtliche Effekte makroskopisch zu erklären. Andererseits werden die Hypothesen nur für signifikante Untermengen der Abweichungen formuliert und erklären auch in der Kombination nicht zwangsläufig alle Abweichungen.
- **Mikroskopische Betrachtung:** Ausgewählte Abweichungen werden einzeln betrachtet und versucht die zu den aufgestellten Hypothesen zugehörigen Nullhypothesen zu widerlegen. Eine Betrachtung aller  $\mathcal{A}^-$  erfolgt aufgrund der Anzahl nicht.
- **Teilevaluation:** Identifizierte Herausforderungen sowie Unzulänglichkeiten der Referenzimplementierung werden als Teilevaluation diskutiert und die Auswirkungen auf die Automatisierung von Straßenbahnen bewertet.

Abschließend erfolgt eine gesonderte Betrachtung aller  $\mathcal{A}^+$  in einem Kapitel, da diese wie oben aufgezeigt streng betrachtet nicht zweifelsfrei auf einem bestimmten Grund und somit ein zugehöriges Modul zurückgeführt werden können.

## 5.1 $\mathcal{A}^-$ Lichtsignalanlagen

### 5.1.1 $\mathcal{A}_{\text{LSA}}^-$ Makroskopische Betrachtung

Der Datensatz beinhaltet 45.118 Vorbeifahrten an LSA wobei zu beachten ist, dass es sich hierbei um wiederholte Vorbeifahrten an denselben Standorten handelt. Dabei treten 5.739  $\mathcal{A}_{\text{LSA}}^-$  auf. Bei allen gilt, dass das System verzögert (also nicht nur weniger stark beschleunigt) hat. Makroskopisch wird die Analyse in bekannte und unbekannte Signalzustände unterteilt.

#### $\mathcal{A}_{\text{LSA}}^-$ ohne Detektion

Von den identifizierten  $\mathcal{A}_{\text{LSA}}^-$  sind 4.399, folglich mit etwa 77 % die Mehrheit, auf eine fehlende Detektion des Signalzustandes zurückzuführen. Entsprechend der in Kapitel 4.4.6 vorgestellten Zustandserfassung zu LSA handelt es sich dabei nicht um Momentanbetrachtungen, sondern im Rahmen des beschriebenen Ringspeichers um noch nicht detektierte LSA oder um solche, bei denen durch Verdeckungen oder ähnliches die Detektionen wie beschrieben mindestens 1 s ausbleiben. Der Signalzustand der LSA ist somit unbekannt und entsprechend der Verhaltensplanung wird gebremst, um eine Überfahrt des unbekanntes Signals zu verhindern.

In diesem und den nachfolgenden Kapiteln sind zur makroskopischen Auswertung verschiedene Messgrößen als empirische kumulative Verteilungsfunktion (eCDF) dargestellt. Die eCDF gibt als Werkzeug der Statistik an, wie viele Datenpunkte in einem Datensatz kleiner oder gleich einem bestimmten Wert sind. Sie zeigt die kumulierte Häufigkeit der Datenpunkte und ermöglicht es, Verteilungsmuster in den Daten zu analysieren. In nachfolgender Abb. 5-2 ist die Verteilung dieser Abweichungen ohne Detektionen als eCDF dargestellt. Durch die Unterteilung in die genutzten Kameras ist ersichtlich, dass nur in vier Fällen die LSA in keinem FoV der fünf Kameras war. Aufgrund der geringen Anzahl und der Tatsache, dass im Gegensatz zu *Silent Testing* bei einer aktiven Umsetzung der Automatisierung der Haltepunkt so gewählt und eingehalten werden kann, dass die LSA stets im FoV ist, wird auf eine weitere Betrachtung dieser Fälle verzichtet.

Wird exemplarisch ein Abstand von 10 m zwischen Haltepunkt und Bahn als Nahbereich betrachtet, so zeigt die nachfolgende eCDF in Abb. 5-2, dass nur etwa 15 % der Abweichungen in diesem Bereich auftreten. Im Umkehrschluss zeigt die Darstellung, dass Probleme mit der Detektion insbesondere bei höheren Abständen auftreten. Dies entspricht den Erwartungen, da mit dem Abstand auch die Anzahl der Pixel bezüglich der LSA abnimmt. Diese potenzielle Ursache wird als Hypothese 1 formuliert und die Überprüfung erfolgt durch eine mikroskopische Strichprobenbetrachtung im nachfolgenden Unterkapitel.

**Hypothese 1 ( $H_{LSA1}$ ):** Die Erkennungsleistung ist für die erforderlichen Abstände (resultierend aus der geforderten Verzögerungen) nicht ausreichend.

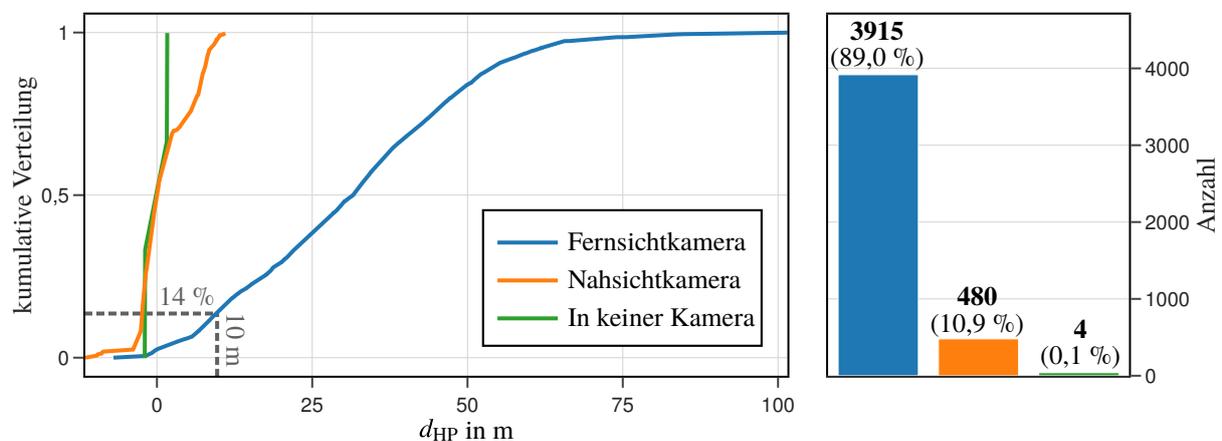


Abbildung 5-2: Verteilung der Abweichungen ohne Detektion der LSA. In der eCDF kann der Abstand  $d_{HP}$  negativ sein, wenn die Abweichung auftritt, sobald der Fahrer über den Kartenbasierten Haltepunkt hinaus fährt.

Für die Nahsichtkameras treten alle Abweichung ohne Detektion im Bereich  $d_{HP} < 11,0$  m auf. Dies liegt in erster Linie daran, dass die Nahsichtkameras erst dann für die Erkennung genutzt werden, wenn die LSA nicht mehr im FoV der Fernsichtkameras ist, d. h. sich das Fahrzeug bereits nah an der LSA befindet. Als potenzielle Ursache der Abweichung lässt sich aufgrund der Fischaugenobjektive die starke Verzeichnung der Nahsichtkameras vermuten, insbesondere in Randbereichen des FoV. Dies ist jedoch makroskopisch nicht weiter zu überprüfen, weshalb

es als mögliche Ursache in Form der Hypothese  $\mathbf{H}_{\text{LSA}2}$  für die nachfolgende mikroskopisch Betrachtung formuliert wird.

**Hypothese 2 ( $\mathbf{H}_{\text{LSA}2}$ ):** Die Verzeichnung von Fischaugenkameras führt zu einer unzureichenden Erkennungsleistung in Randbereichen des FoV.

Da die 4.402  $\mathcal{A}_{\text{LSA}}^-$  ohne Detektion — im Kontext aller 15.627 Abweichungen  $\mathcal{A}$  — aufgrund des Aufwandes nicht vollständig einzeln betrachtet werden können, beschränkt sich die nachfolgende mikroskopische Betrachtung auf Strichproben. Zur Identifikation systematischer Ursachen sowie bevorzugt mikroskopisch zu betrachtender LSA werden die  $\mathcal{A}_{\text{LSA}}^-$  ohne Detektion ihren jeweiligen LSA zugeordnet und auf die Anzahl aller Vorbeifahrten an diesen, also auch solchen ohne Abweichung, bezogen. Hierdurch werden LSA hervorgehoben, die besonders problematisch bezüglich einer fehlenden Detektion auffallen.

In nachfolgender Abb. 5-3 ist für jede LSA die Anzahl der Abweichungen an dieser bezogen auf die Vorbeifahrten dargestellt. Dabei sind die Balken nach der für die an der LSA erlaubten Höchstgeschwindigkeit gruppiert. Jeder Balken repräsentiert somit eine LSA der Realität. Da der menschliche Fahrer jedoch entgegen der erlaubten Höchstgeschwindigkeit (wiederholt) signifikant langsamer gefahren sein kann, sind die Balken zusätzlich farblich nach dem Abstand  $d_{\text{HP}}$  zwischen Bahn und dem zur jeweiligen LSA zugehörigem Haltepunkt bei Auftreten der Abweichung eingefärbt.

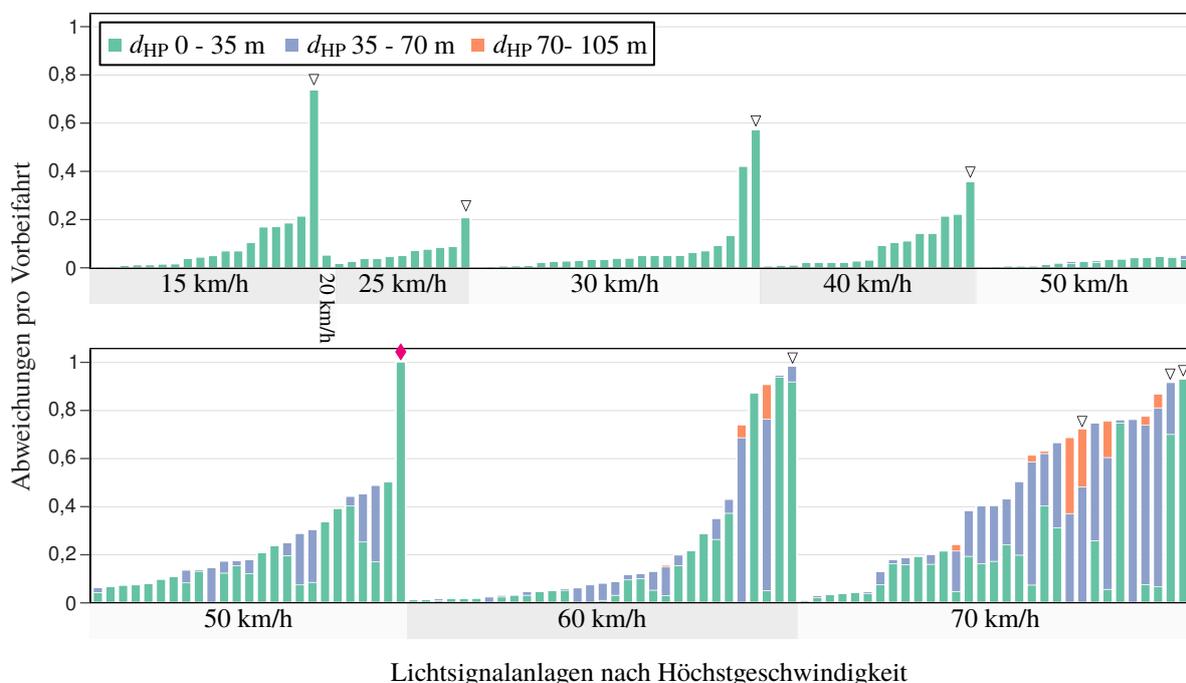


Abbildung 5-3:  $\mathcal{A}_{\text{LSA}}^-$  ohne Detektion bezogen auf die Anzahl aller Vorbeifahrten der jeweiligen Haltestelle. Gruppirt nach der für die an der LSA erlaubten Höchstgeschwindigkeit. Zusätzlich farblich nach dem Abstand  $d_{\text{HP}}$  zwischen Bahn und dem zur jeweiligen LSA zugehörigem Haltepunkt eingefärbt.

Hohe Balken spiegeln LSA wider, bei denen bezogen auf die Vorbeifahrt häufig eine Abweichung auftritt und die somit von besonderem Interesse für die mikroskopische Untersuchung sind. So zeigt bspw. der rechts äußere Balken der Gruppe mit der Höchstgeschwindigkeit von 50 km/h (mit  $\blacklozenge$  gekennzeichnet) ein Verhältnis von 1,0. Das bedeutet, dass der Zustand bei jeder Vorbeifahrt an dieser bestimmten LSA zum Zeitpunkt einer erforderlichen Reaktion unbekannt ist. Dieser Zeitpunkt der erforderlichen Reaktion resultiert aus den in Kapitel 4.4.8 vorgestellten Bedingungen zu Mindestverzögerung oder Unterschreitung eines Mindestabstandes für die Reaktion des OuT auf eine LSA mit unbekanntem Zustand. Der Wert 1,0 deutet also auf eine systematische Unzulänglichkeit bezüglich der geforderten Detektionsleistung hin, sagt jedoch nicht aus, dass es bei weiterer Annäherung an die LSA nicht doch zu einer erfolgreichen Bestimmung des Signalzustandes kommt.

In der mikroskopischen Betrachtung werden Messfahrten dieser LSA sowie aufgrund der Signifikanz in Form der vergleichsweise hohen Anzahl an Abweichungen und der zugehörigen Distanzen die mit  $\nabla$  gekennzeichneten LSA näher betrachtet. Zusätzlich geht aus der oben gezeigten Abb. 5-3 hervor, dass insbesondere in den Gruppen mit höherer Höchstgeschwindigkeit und damit mehrheitlich auch höherer Distanz  $d_{HP}$  die Balken vergleichsweise höher und Abweichungen somit häufiger sind. Dies verstärkt makroskopisch die Erwartung, dass die Erkennungsleistung mit zunehmender Distanz abnimmt.

### $\mathcal{A}_{LSA}^-$ mit Detektion

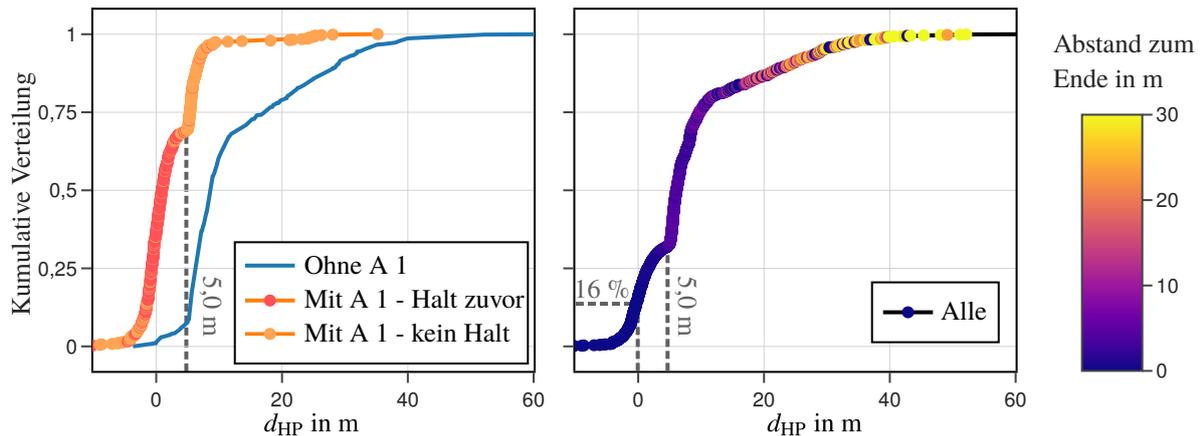
Vor der mikroskopischen Betrachtung ausgewählter Abweichungen ohne Detektion werden zuvor die verbleibenden 1.340  $\mathcal{A}_{LSA}^-$  makroskopisch betrachtet, bei denen es zwar eine Detektion gab, das System jedoch gebremst hat. Für alle 1.340  $\mathcal{A}_{LSA}^-$  wurde ein F0 detektiert und das OuT hat entsprechend einen Halt geplant. Aufgrund des Einsatzes eines nicht zu validierenden maschinellen Netzes zur Erkennung des Signalzustandes sind einige Fehldetektionen (in der Realität wird kein F0 gezeigt) wahrscheinlich. Da diese 1.340  $\mathcal{A}_{LSA}^-$  im Median etwa 0,8 s dauern und der Blickwinkel sich aufgrund der Bewegung der Bahn verändert, erscheinen Fehldetektion als alleinige Erklärung für all diese Abweichungen jedoch unplausibel.

Im Gegensatz impliziert dies, dass der Fahrer bereits losfährt, obwohl die LSA noch F0 also Halt zeigt oder sich ungebremst nähert, während der OuT plant zu bremsen. So befinden sich etwa 47 % der 1.340 Fälle an LSA, die zu Haltestellen gehören. Diese verfügen meist zusätzlich über das Signal A 1, welches dem Fahrer anzeigt, den Fahrgastwechsel zu beenden und die Türen zu schließen, da die LSA zeitnah die Fahrt freigeben wird.

In der nachfolgenden Abb. 5-4 (a) ist die Aufteilung der  $\mathcal{A}_{LSA}^-$  getrennt nach LSA mit und ohne A 1 als eCDF des Abstandes zum Haltepunkt gezeigt. Die Mehrheit der Abweichungen an LSA mit A 1 erfolgt im unmittelbaren Nahbereich und einem Halt in den letzten 3 s vor Auftreten der Abweichung (gekennzeichnet mit  $\bullet$ ), weshalb die zugehörige Hypothese 3 aufgestellt wird.

**Hypothese 3 ( $H_{LSA3}$ ):** Der Fahrer fährt aus dem Stillstand bereits bei  $F0$  los in Antizipation vor Erreichen der LSA ein Fahrt freigebendes Signal zu erhalten.

Der Knick in der Steigung der eCDF bei 5,0 m resultiert aus der zuvor in Kapitel 4.4.8 aufgezogenen Verhaltensplanung für LSA, bei der entweder ab einer erforderlichen Verzögerung von  $-0,5 \text{ m/s}^2$  oder ab einer Annäherung unter 5,0 m auf diese reagiert wird. In Abb. 5-4 (b) werden die Kurven der linken Darstellung gesamtseitlich betrachtet und alle 1.340  $\mathcal{A}_{LSA}^-$ , bei denen es zwar eine Detektion gab, das System jedoch gebremst hat, als eCDF des Abstandes dargestellt.



(a) Nach Existenz von A 1 aufgeteilt. ● kennzeichnet einen Halt und ○ keinen Halt in den 3 s vor Auftreten der Abweichung.

(b) eCDF aller  $\mathcal{A}_{LSA}^-$  mit Detektion (Vereinigung der beiden linken Kurven). Eingefärbt nach verbleibendem Abstand bei Ende der Abweichung.

Abbildung 5-4: eCDF der Distanz bei Eintreten der Abweichung. Der Knick bei 5,0 m resultiert aus der Reaktionsbedingung im Verhaltensplaner:  $a_{\text{soil},LSA} < -0,5 \text{ m/s}^2 \vee d_{\text{ego},LSA} < 5,0 \text{ m}$ .

Zusätzlich ist in Abb. 5-4 (b) farblich kodiert, wie weit die Abweichung vom Haltepunkt entfernt wieder endet und damit Fahrer sowie OuT ein ähnliches Verhalten aufweisen. Anhand der Verteilung der farblichen Kodierung ist ersichtlich, dass Abweichungen, die in größerer Distanz auftreten auch mit vergleichsweise großer Distanz vor der LSA enden. Dies zeigt, dass der Fahrer nicht über  $F0$  fährt und das OuT nicht weiter plant zu verzögern. Daher wird die Hypothese 4 formuliert, um einen Teil der beobachteten Abweichungen somit als mögliche Schwierigkeit bei der Anwendung von *Silent Testing* zu beschreiben.

**Hypothese 4 ( $H_{LSA4}$ ):** Der Fahrer fährt bei Annäherung an die LSA trotz  $F0$  ungebremst weiter. Er antizipiert vor Erreichen der LSA ein Fahrt freigebendes Signal zu erhalten.

Zusätzlich zeigt Abb. 5-4 (b), dass etwa 16 % der Abweichungen mit  $d_{HP} \leq 0$  nach dem kartenbasierten Haltepunkt auftreten. Neben den oben genannten möglichen Gründen zeigt dies einen Nachteil in der Anwendung von *Silent Testing*. Da die LSA von Straßenbahnen nicht über auf dem Boden markierte Haltelinien verfügen, halten die Fahrer sowohl vor wie auch nach denen in der Karte hinterlegten Haltepunkten. Hält ein Fahrer wesentlich nach dem empirisch bestimmten Haltepunkt führt dies in einigen Fällen zu einer  $\mathcal{A}_{LSA}^-$ , da das OuT stark verzögert, um möglichst schnell nach dem Haltepunkt zu halten.

Es handelt sich hierbei jedoch nicht um eine eindeutige Unzulänglichkeit der Referenzimplementierung oder Herausforderung der Automatisierung von Straßenbahnen, sondern um Schwächen der gewählten Methode zur Identifikation der Abweichung für *Silent Testing*. Für die reine Anwendung von *Silent Testing* zur Identifikation von Herausforderungen der Automatisierung wären diese fälschlich identifizierten Abweichungen in einer zukünftigen Anwendung mit zusätzlichen Bedingungen wie bspw. einer Überprüfung, ob zwar nach dem Haltepunkt aber noch vor der LSA gehalten worden ist, reduzierbar.

Zur Prüfung der aufgestellten Hypothesen und Auswahl mikroskopisch näher zu betrachtenden LSA ist wie oben in Abb. 5-3 ein Balkendiagramm erstellt, welches für jede reale LSA die Anzahl der Abweichungen ins Verhältnis zu den Vorbeifahrten an dieser LSA setzt. Für die mikroskopische Betrachtung sind LSA mit vergleichsweise häufigen Abweichungen aufgrund ausbleibender Detektionen ausgewählt. Das Balkendiagramm ist in Anhang B.1.

### 5.1.2 $\mathcal{A}_{LSA}^-$ Mikroskopische Betrachtung

Die Prüfung der Verifikation der aufgestellten Gegenhypothese  $\mathbf{H}_{LSA}$  erfolgt durch das Bilden und Widerlegen der komplementären Nullhypothese  $\mathbf{H}_{LSA}^0$ . Im Rahmen der mikroskopischen Betrachtung werden Beispiele zum Widerlegen dieser Nullhypothese gesucht. Aus Gründen der Übersichtlichkeit wird nachfolgend auf die formale Ausformulierung aller Nullhypothese verzichtet.

Die aufgestellte  $\mathbf{H}_{LSA} \mathbf{1}$  vermutet die Unzulänglichkeit der Erkennung auf größere Distanzen. Die zugehörige Nullhypothese  $\mathbf{H}_{LSA}^0 \mathbf{1}$  drückt somit aus, dass es keine Unzulänglichkeiten aufgrund der Entfernung gibt. Die Widerlegung dieser Nullhypothese erfolgt mit dem nachfolgend in Abb. 5-5 gezeigten Beispiel. In dem in der Abbildung dargestellten Szenario fährt die Straßenbahn mit etwa 70 km/h und hat in dem linken Bild 5-5 (a) einen Abstand von etwa 96 m zur LSA und etwa 94 m zum zugehörigen Haltepunkt. Für einen Halt müsste die Bahn zu diesem Zeitpunkt bereits mit einer normalen Bremsung von  $-2,0 \text{ m/s}^2$  verzögern. Der vertikale Lichtbalken im Signalfeld des angezeigten F 1 ist nur etwa 6 Pixel hoch und der gelernte Detektor erkennt das Signal nicht. Etwa 3 s später hat sich die Bahn dem Signal auf 38 m genähert und das Signal wie in Abb. 5-5 (b) dargestellt erstmalig als F 1 detektiert. Zu diesem Zeitpunkt wäre für einen Halt am zugehörigen Haltepunkt bereits eine nicht mehr umsetzbare Verzögerung von  $-4,7 \text{ m/s}^2$  erforderlich. Insbesondere, da in diesem Beispielszenario die Umgebungsbedingungen gut sind und die LSA nicht durch andere Objekte verdeckt ist, gilt die Nullhypothese  $\mathbf{H}_{LSA}^0 \mathbf{1}$  als widerlegt und die Reichweite der Detektion für den gewählten Ansatz wird als nicht ausreichend betrachtet. Auch wenn sich der Zustand in Abb. 5-5 (a) aufgrund der Position innerhalb der LSA (F0 im oberen, F 1 im unteren Bereich) errahnen lässt, ist insbesondere die Pixeldichte aufgrund der Kombination aus Auflösung sowie Objektiv und nicht der eingesetzte YOLOv5 Detektor oder dessen Trainingsstrategie als Grund zu nennen.



(a) Keine Detektion bei etwa 96 m Abstand. Die ROI ist  $36 \times 34$  Pixel groß, während der vertikale Lichtbalken des Signals nur etwa 6 Pixel hoch ist.

(b) Erste Detektion bei etwa 38 m Abstand. Die ROI ist  $71 \times 49$  Pixel groß, während der vertikale Lichtbalken des Signals nur etwa 11 Pixel hoch ist.

Abbildung 5-5: Ausfälle der Detektion bei größerer Distanz.

Für die Nahsichtkameras wurde ein ähnliches Szenario in den Messdaten identifiziert. Aufgrund einer innerstädtischen engen  $90^\circ$  Abbiegung ist eine LSA nicht mehr im FoV der Fernsichtkameras und eine der Nahsichtkameras muss zur Detektion eingesetzt werden. Wegen einer querenden Straße befindet sich die LSA jedoch aufgrund von beengten Platzverhältnissen erst hinter dieser querenden Straße, während der zugehörige Haltepunkt vor der querenden Straße liegt. Die LSA kann in etwa 17,7 m Entfernung a posteriori auch durch einen Menschen trotz guter Umgebungsbedingungen aufgrund zu geringer Auflösung im Kamerabild nicht mehr erkannt werden (Darstellung in Anhang B.2).

In  $H_{LSA}2$  wird eine reduzierte Detektionsleistung aufgrund der Verzeichnung der Fischaugenobjektive vermutet. Dazu ist nachfolgend in Abb. 5-6 ein Szenario gezeigt, bei dem die LSA durch Annäherung der Bahn in den Randbereich der Nahsichtkamera gelangt, gleichzeitig nimmt durch die Annäherung die Pixeldichte der ROI um etwa 17 % zu, was der maschinellen Erkennung dienlich sein sollte. In der ROI ist zu erkennen, dass einerseits die Verzeichnung der LSA zunimmt, andererseits aber insbesondere durch die wechselnde Perspektive die gesamte LSA von unten betrachtet wird. Dies führt dazu, dass die Signalfelder von unten betrachtet für den Detektor anders aussehen.

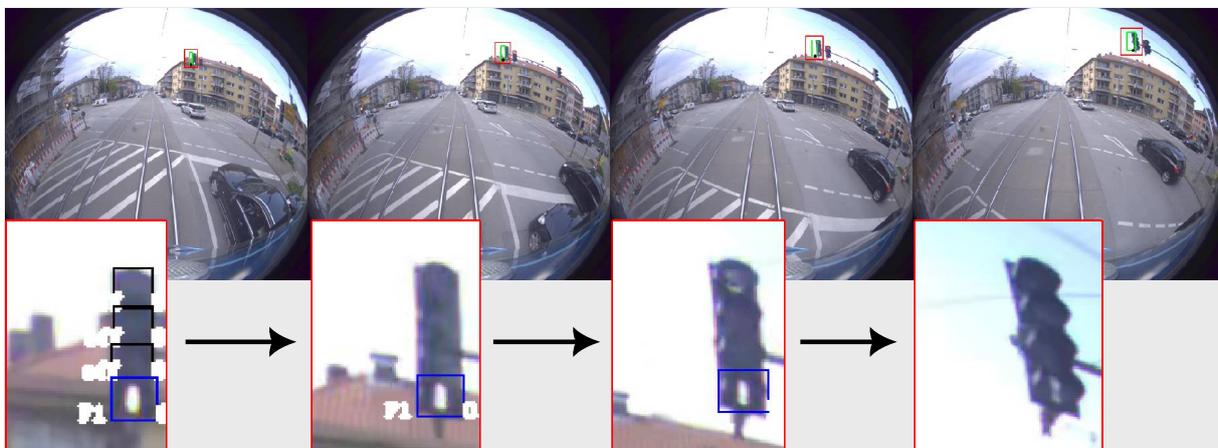


Abbildung 5-6: Beispielszenario I für Einfluss der Verzeichnung und Perspektive auf die Erkennung von LSA. Im rechten Bild wird der Signalzustand nicht mehr erkannt.

Darüber hinaus verliert der Lichtbalken vermutlich aufgrund von gerichtetem ausfallendem Licht mittels Streulinse an Intensität. Damit ist für dieses Beispiel kein eindeutiger Zusammenhang zwischen der Verzeichnung und der fehlenden Detektion identifizierbar, jedoch zeigt der Perspektivwechsel das unterschiedliche Aussehen und weist zumindest auf eine unzureichende Generalisierungsfähigkeit des Detektors hin, da von unten betrachtete LSA nicht in der Trainingsstrategie enthalten sind.

Als zweites Szenario ist in Abb. 5-7 ebenfalls die Annäherung unter Nutzung der mittleren Nahsichtkamera gezeigt. Die niedriger hängende Doppel-LSA bewegt sich dabei in den Randbereich der ROI und die Verzeichnung nimmt zu. Einerseits wird in der rechten LSA das Fahrt freigebende F2 nicht mehr detektiert, andererseits wird in der linken LSA das angezeigte F0 fälschlich als F3 detektiert. Während die ausbleibende Detektion auch auf den Perspektivwechsel und die reduzierte Intensität des Lichtbalkens zurückgeführt werden kann, ist die Fehldetektion des F0 als F3 auf die Verzeichnung zurückzuführen. Die Verzeichnung führt dazu, dass der Lichtbalken des F0 nicht mehr horizontal, sondern nach links oben geneigt ist und der Detektor das Signal fälschlich als das diagonal von links oben nach rechts unten zeigendes F3 detektiert. Die Verzeichnung ist somit als Ursache für fehlerhafte Detektionen identifiziert und die Hypothese  $H_{LSA2}$  gilt als verifiziert.

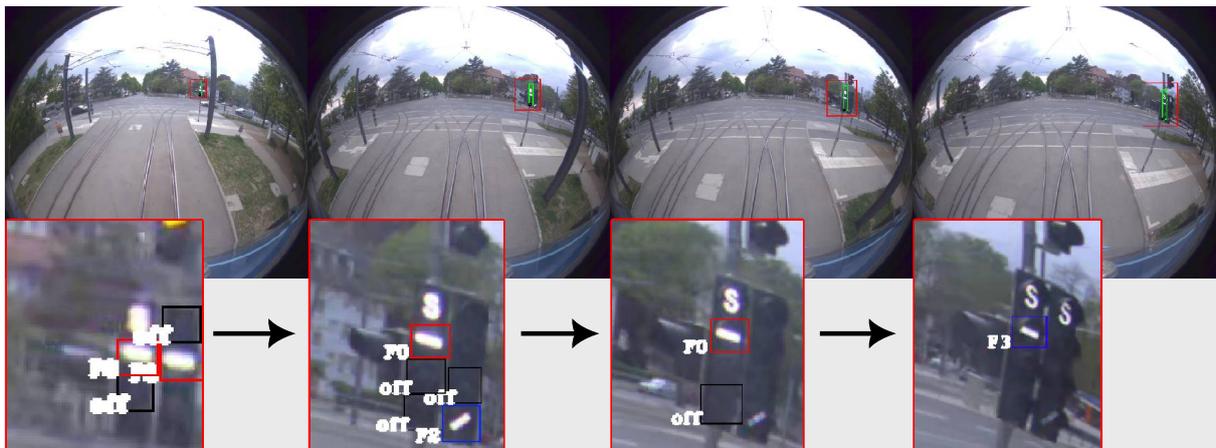


Abbildung 5-7: Beispielszenario II für Einfluss der Verzeichnung und Perspektive auf die Erkennung von LSA. Im rechten Bild wird der Signalzustand der linken LSA fälschlich als F3 und der rechten LSA nicht mehr erkannt.

Für die Falsifizierung der Nullhypothesen zu  $H_{LSA3}$  sowie  $H_{LSA4}$ , bei denen der Fahrer vermeintlich trotz F0 nicht bremst, sind 35 Abweichungen mit detektiertem F0 mikroskopisch untersucht. In allen betrachteten Beispieldaten zeigte die LSA tatsächlich ein F0. Unter den untersuchten 35 Abweichungen traten 17 an Haltestellen mit zusätzlichem A2 Signal auf.

Wie nachfolgend exemplarisch in Abb. 5-8 gezeigt, fahren die Fahrer in den untersuchten Abweichungen kurz nach dem Aufleuchten des Signals A2, welches auf ein Schließen der Türen zum Herstellen der Abfahrtbereitschaft signalisiert, trotz F0 los. Das OuT versucht die vom Fahrer aufgebaute Geschwindigkeit abzubauen und es kommt zur identifizierten Abweichung.

In den meisten Szenarien wechselt die LSA kurz vor dem Überfahren auf F 1–3. In einzelnen betrachteten Messreihen ist das Umschalten aber nicht mehr sichtbar, da die LSA mit der Front der Bahn bereits passiert wurde und diese so außerhalb der FoV aller Kameras ist.  $H_{LSA}3$  zum Anfahren trotz F 0 wird somit als verifiziert betrachtet. Dabei handelt es sich jedoch nicht um eine Herausforderung der Automatisierung von Straßenbahnen, sondern um eine Herausforderung bei der Anwendung von *Silent Testing*. Andere Messdaten ohne Abweichung zeigen, dass die Fahrer teilweise auch auf das Fahrt freigebende Signal warten, obwohl A 2 aufleuchtet und das menschliche Verhalten zum besonders sicherheitsrelevanten Anfahren somit nicht deterministisch ist.



Abbildung 5-8: Beispielszenario für Anfahren trotz F 0. Ganz links steht die Straßenbahn und A 2 (ganz unten) beginnt zu leuchten. Durch das darauf Zufahren, ist die LSA nach dem dritten Bild außerhalb des FoV der Fernsichtkamera. Sichtbar in der rechten Nahsichtkamera wechselt das Signal auf F 1, die Bahn ist entsprechend der Lokalisierung zu diesem Zeitpunkt etwa 15 cm vor der LSA.

Auch  $H_{LSA}4$ , das Bewusste ungebremste menschliche Annähern an eine LSA mit F 0 gilt als verifiziert, da in den untersuchten Abweichungen die Fahrer trotz F 0 weiter gefahren sind. Da es in diesen Fällen kein A 2 gibt und die Straßenbahn bereits rollt, lässt sich nur erahnen welche Indikatoren genutzt werden. Die Fahrer scheinen je nach Lokalität den Wechsel von F 0 zu einem Fahrt zeigenden Signal anhand verschiedener Merkmale zu antizipieren, bspw.: der kreuzende Verkehr hält bereits an seiner LSA, die Bestätigung der Signalanforderung als blinkendes „S“, doppelte LSA hintereinander, die in einem festen Intervall nachfolgend schalten. Als extremes Beispiel wurde ein Szenario identifiziert, bei dem die Bahn mit etwa 40 km/h auf die LSA eines Bahnübergangs zufährt. Bereits 98 m vorher blinkt ein gesondert aufgestelltes „S“ und die kreuzenden Verkehrsteilnehmer stehen bereits an ihrer LSA des Bahnübergangs. Erst wenn die Straßenbahn 4,3 m vor der LSA (nicht dem Haltepunkt) ist, wechselt das Signal auf F 1, zu diesem Zeitpunkt wäre eine Verzögerung von  $-14,1 \text{ m/s}^2$  erforderlich.

In einer von 40 mikroskopisch betrachteten  $\mathcal{A}_{LSA}^-$  ohne Detektion wurde ein Szenario identifiziert, in welchem die LSA für die vollständige Vorbeifahrt ausgeschaltet erscheint. Die nachfolgende Abb. 5-9 zeigt im oberen Bereich die Bilder der rechten Fernsichtkamera und im unteren Bereich die Bilder der linken Fernsichtkamera bei Annäherung an die LSA. In der rechten Fernsichtkamera ist das Signal für die vollständige Vorbeifahrt nicht sichtbar, während es in der linken Fernsichtkamera gut erkennbar ist. Auch das benachbarte grüne Signal des Individualverkehrs ist in der rechten Kamera schwächer. Sonst wirken die Bilder der rechten und linken Kamera gleich. LED-LSA flackern aufgrund der genutzten Art von Netzteilen sowie der Versorgung mit

Wechselspannung für das menschliche Auge nicht sichtbar mit bis zu 100 Hz.<sup>169, 170</sup> Zusätzlich sind LSA durch eine Pulsweitenmodulation dimmbar,<sup>171</sup> was ebenfalls kurze Zeitlücken verursacht, in denen die LED aus sind. Es ist zu vermuten, dass in der gezeigten Szene die Kamerafrequenz von 10 Hz sowie die kurze Belichtungszeit aufgrund des Sonnenlichtes zufällig mit den Aus-Zeitpunkten dieses Flackerns zusammenfällt.

Dedizierte Versuche mit sehr kurzen Belichtungszeiten haben gezeigt, dass die LSA kurzzeitig nicht leuchten und der Effekt für verschiedene Standorte (Modelle) unterschiedlich ausgeprägt auftritt. Für den in Abb. 5-9 gezeigten Standort sind 142 Vorbeifahrten manuell ausgewertet. In 25 % der Vorbeifahrten war das Signal in mindestens einer der beiden Fernsichtkameras nicht oder zumindest für einige Sekunden nicht sichtbar. In allen diesen Fällen war es sonnig, was auf eine kurze Belichtungszeit schließen lässt. Bei 3 % der Fälle war das Signal in beiden Fernsichtkameras nicht sichtbar, jedoch war das benachbarte grüne Signal des Individualverkehrs in allen 142 Fällen sichtbar. Zur Klärung, ob der Effekt bei den weißen Signalen des ÖPNV grundsätzlich ausgeprägter als bei den farbigen Elementen des Individualverkehrs ist, sind weitere Untersuchungen außerhalb dieser Arbeit erforderlich.



Abbildung 5-9: Oben rechte Fernsichtkamera, unten linke Fernsichtkamera. Das Signal ist im rechten Kamerabild nicht sichtbar. Die Vergrößerungen entsprechen nicht der ROI sondern dienen der besseren Erkennbarkeit.

Darüber hinaus sind in der mikroskopischen Betrachtung der  $\mathcal{A}_{LSA}^-$  weitere Gründe identifiziert, die in ähnlichem Maße auch für Kraftfahrzeuge gelten und daher erwartbar sind. Zugehörige Beispielbilder befinden sich in Anhang B.1:

1. **Gegenlicht:** Je nach Witterung und Tageszeit kommt es zu starkem Gegenlicht durch die Sonne. Je nach Stärke ist in diesen Fällen nicht nur das Signal, sondern die ganze LSA nicht mehr zu erkennen.

169 Wu, Z. et al.: Hybrid LED traffic light detection using high-speed camera (2016), S. 1237.

170 Yabuuchi, K. et al.: Traffic Light Detection with Frequency Patterns (2020), S. 4.

171 SWARCO: FUTURLED 6 (2023).

2. **Witterung:** Aufgrund von Regen, Schnee und Nebel wird die Sicht eingeschränkt und die Signale sind nicht mehr zu erkennen. Obwohl sich die Fernsichtkameras innerhalb des überwachten Bereichs hinter der Windschutzscheibe befinden, können aufgrund der Nähe zu diesen bereits einzelne Tropfen auf der Windschutzscheibe die Sicht der Kamera stark beeinträchtigen.
3. **Blickwinkel und Anordnung der Kameras:** Obwohl durch den 180° FoV der Nahsichtkameras die LSA meist im Bild sind, kommt es aufgrund der hohen Positionierung der Kameras am Fahrzeug zu Verdeckungen des Signals durch den am Signalfeld befestigten Signalschirm, welcher das Signal vor einfallendem Sonnenlicht schützen soll.
4. **Verdeckung durch andere Objekte:** Aufgrund von Bäumen, anderen Verkehrsteilnehmern etc. sind LSA teilweise erst spät oder aufgrund der Anordnung der Kameras (s.o.) gar nicht sichtbar.
5. **Fehler Detektor:** Obwohl das Signal menschlich erkennbar ist, wird es vom Detektor nicht erkannt. Auch wenn ein besserer Detektor sowie eine bessere Trainingsstrategie als die Umsetzung im Rahmen der Referenzarchitektur zum Einsatz kommt, weisen derzeitige Detektoren immer Fehler auf. So hat bspw. der erstplatzierte Detektor des COCO Objekt Benchmarks<sup>172</sup> einen  $AP^{50} \% = 78 \%$ . Das bedeutet, dass 22 % der annotierten Objekte in den Testdaten nicht mit mindestens einer flächenmäßigen Übereinstimmung von 50 % Fläche der Boundingboxen erkannt werden.

Auch wenn die genannten Punkte 1–2 auch für Kraftfahrzeuge gelten, bilden diese für die Straßenbahn bzw. den ÖPNV verstärkte Herausforderungen. Im Gegensatz zum Kraftfahrzeugverkehr verfügen die Signale des ÖPNV über keine farblichen Merkmale zur Erkennung und ändern als kleineres monochromes Rechteck bereits in 45° Schritten ihre Bedeutung sicherheitsrelevant zwischen Halten und Fahren. Zwar gibt es im Kraftfahrzeugbereich auch Pfeile als Signale, diese sind jedoch zusätzlich farblich gekennzeichnet und bieten durch eine komplexere Form mehr Merkmale zur eindeutigen maschinellen Erkennung.

Weiterhin sind nachfolgende Gründe für Abweichungen identifiziert, die insbesondere die Anwendung von *Silent Testing* oder die umgesetzte konkretisierte Referenzarchitektur betreffen, jedoch nicht die Automatisierung von Straßenbahnen im Allgemeinen:

- **Falsche Haltepunkte:** Es sind systematische (zu einigen LSA) Abweichungen zwischen denen in der Karte hinterlegten sowie denen von Fahrern gewählten Haltepunkten identifiziert. Dies führt dazu, dass das OuT entweder zu früh oder zu spät bremst. Dies ist insbesondere für die Anwendung von *Silent Testing* problematisch, da mittels einfachem Schwellwertvergleich von  $\Delta a$  falsch positive Abweichungen sowohl als  $\mathcal{A}^-$  wie auch als  $\mathcal{A}^+$  (je nachdem ob der Fahrer signifikant früher oder später hält) identifiziert werden.

---

<sup>172</sup> Lin, T.-Y. et al.: Microsoft COCO (2015), Unterseite „Detection-Leaderboard“.

- **Fahrerreaktion:** Einige wenige Abweichungen lassen sich auf eine späte und vergleichsweise starke bis sehr starke Bremsung des menschlichen Fahrers zurückführen. Durch die Bedingung  $|\Delta a| \approx 2,0 \text{ m/s}^2$  reicht es, wenn nur sehr kurz der Fall eintritt, dass das System bereits verzögert der menschliche Fahrer aber noch beschleunigt, nur um kurz darauf selbst stark zu verzögern. Dabei handelt es sich weder um Fehlverhalten der Fahrer, noch des OuT, sondern um Varianz im erlaubten Verhalten.

### 5.1.3 $\mathcal{A}_{\text{LSA}}^-$ Teilevaluation

Grundsätzlich können LSA der Straßenbahn bzw. allgemein des ÖPNV mit den gleichen Methoden detektiert werden, wie diese auch für assistierte oder automatisierte Kraftfahrzeuge umgesetzt werden. Insbesondere war die Lokalisierung, der Abruf der kartenbasierten Pose, die Vermessung der Positionen der LSA und damit die Generierung der ROI in keiner mikroskopischen Betrachtung Grund für ein Ausbleiben der Detektion. Jedoch kann dies aufgrund der Vielzahl der  $5.739 \mathcal{A}_{\text{LSA}}^-$  auch nicht ausgeschlossen werden und gilt daher nur als plausibilisiert. Als wesentliche Gründe für ein Ausbleiben der Detektion haben sich insbesondere Faktoren wie FoV, Auflösung der Kamera, die Verzeichnung durch Kameras selbst oder unbekannte Wirkketten des gelernten Detektors herausgestellt. Durch noch mehr Kameras mit jeweils kleinerem FoV (weniger Verzeichnung) sowie höheren Auflösung, einer verbesserten Trainingsstrategie und ggf. einem anderen Detektor wäre ein Teil dieser Abweichungen reduzierbar. Dennoch warten die weißen LSA des ÖPNV mit den aufgezeigten zusätzlichen Herausforderungen wie weniger Merkmale zur Detektion, größerem Einfluss von Umgebungseinflüssen wie Gegenlicht und Witterung auf. Hinzu kommen grundsätzliche Herausforderung bei der Validierung maschinell gelernter Systeme als Teil eines sicherheitsrelevanten Systems. Darüber hinaus sind zusätzliche Maßnahmen hinsichtlich der Manipulationssicherheit erforderlich, um kamerabasierte Detektoren vor bewusst sicherheitsrelevanten Manipulationen zu schützen. So haben bspw. Nassi et al.<sup>173</sup> für mehrere Millisekunden falsche Geschwindigkeitsschilder in Bäume projiziert, die von einem kamerabasierten Assistenzsystem für Kraftfahrzeuge als echte Schilder erkannt wurden. Ein ähnlicher Angriffsvektor z. B. mit überklebten Signalen, ist auch für den hier vorgestellten Detektor plausibel. Im Kraftfahrzeugbereich wird bereits aktiv daran geforscht, diese Fehler maschineller Netze früh zu erkennen, wie bspw. die von Hacker und Seewig entwickelten Mechanismen zur Überwachung eines Detektors zeigen.<sup>174</sup>

Als Alternative zur Lösung dieser kamerabasierten Herausforderungen ist die Anwendung von *Vehicle to Infrastructure* (V2I) bzw. einer äquivalenten Zugsicherung detailliert zu prüfen. Entgegen der im Rahmen der Referenzarchitektur genannten Prämisse eine Automatisierung ohne Änderungen an der Infrastruktur zu ermöglichen, bieten solche Änderungen eine sichere<sup>175</sup>

<sup>173</sup> Nassi, B. et al.: Phantom of the ADAS (2020).

<sup>174</sup> Hacker, L.; Seewig, J.: Insufficiency-Driven DNN Error Detection (2023).

<sup>175</sup> Sowohl im Sinne von *Security* wie auch *Safety*.

Zustandsübermittlung des angezeigten sowie zukünftigen Signals via Funk. Insbesondere für Straßenbahnen ergeben sich im Vergleich zum Kraftfahrzeug nochmals stärkere Motivatoren zum Einsatz von V2I:

- **Geringe Anzahl an LSA:** Im Vergleich zum Kraftfahrzeugverkehr sind die LSA des ÖPNV aufgrund des Linienbetriebes deutlich geringer verbreitet. Die Anwendung von V2I für eine ganze Stadt ist daher für den ÖPNV mit geringerem Aufwand als für alle von Kraftfahrzeugen befahrbaren Straßen verbunden.
- **Verantwortungsbereich:** Für die LSA innerhalb des Einsatzgebietes ist das Verkehrsunternehmen selbst sowie die Stadt oder die umliegenden Städte verantwortlich. Zusätzlich sind Verkehrsunternehmen als Teil der Daseinsvorsorge in der Regel in öffentlicher Hand. Änderungen an LSA sind damit hinsichtlich Hürden und dem Allgemeinzweck einfacher umsetzbar. Für die heute an ÖPNV zumeist eingesetzte Signalanforderung per Funk wird diese Zusammenarbeit bereits genutzt.
- **Nutzung als Assistenzsystem:** Bereits heute, also vor der Automatisierung, könnte eine sichere Zustandsübermittlung der LSA als Assistenzsystem für den menschlichen Fahrer genutzt werden. Neben Sicherheitsfunktionen, wie dem Schutz vor Überfahren eines F0, lassen sich als Assistenzsystem auch Funktionen zu effizienten Fahrweisen bei Annäherung umsetzen.
- **Hoher Nutzungsfaktor:** Für vereinzelt automatisiert fahrende Kraftfahrzeuge die V2I erfordern, müsste die Stadt von Beginn an quasi vollständig mit der Technologie ausgerüstet sein. Demgegenüber sind Straßenbahnen im Mehrschichtbetrieb unterwegs und nutzen die gleichzeitig geringere Anzahl an LSA (pro Stadt) deutlich häufiger. Der Nutzungsfaktor der jeweils mit V2I ausgerüsteten LSA ist damit höher.

Für eine abschließende Bewertung sind außerhalb dieser Arbeit auch die finanziellen Aspekte einer sicheren funkbasierten Übertragung gegenüber einer validierten kamerabasierten Erkennung der LSA abzuwägen sowie die technische Implementierung der verschiedenen aktuellen sowie in Umsetzung befindlichen Standards bezüglich V2I bzw. Zugsicherung zu prüfen. Vor dem Hintergrund der aufgezeigten Herausforderungen der kamerabasierten Erkennung von LSA ist die Anwendung von V2I bzw. einer äquivalenten Zugsicherung als vielversprechend zu bewerten. Darüber hinaus hat die Auswertung der  $\mathcal{A}_{\text{LSA}}^-$  gezeigt, dass trotz des lediglich eindimensionalen Freiheitsgrads der Straßenbahn die Anwendung von *Silent Testing* durch mehrere mögliche richtige Verhalten erschwert ist. Insbesondere die Antizipation der Fahrer, dass das angezeigte Signal F0 wechseln wird sowie die nicht auf dem Boden markierten Haltepunkte an LSA erschweren die Anwendung von *Silent Testing*. Eine aufwendigere Identifikation anstelle des Schwellwertvergleichs mit  $\Delta a_{\text{krit}}$  zur Reduktion von Falsch-Positiven wäre bspw. mit einer *Ground Truth* in Form einer (nicht zwingend sicheren) V2I oder zentralen Erfassung aller Signalzustände möglich. Eine nachträgliche Prüfung eines angezeigten F 1–5 war in den Messdaten in den meisten Fällen

zwar möglich, jedoch sind wie beschrieben auch Abweichungen identifiziert, in denen aufgrund der Vorbeifahrt kein Wechsel des Signals mehr sichtbar war.

## 5.2 $\mathcal{A}^-$ Haltestellen

Im Rahmen der Analyse der Messdaten wurde für Haltestellen (HS) nur eine  $\mathcal{A}_{\text{HS}}^-$  identifiziert. Aus diesem Grund erfolgt keine makroskopische Betrachtung, sondern die direkte mikroskopische Untersuchung der zugehörigen Messreihe. Diese zeigt jedoch, dass es sich um eine falsch positiv identifizierte Abweichung handelt. Wie anhand der Verläufe in nachfolgender Abb. 5-10 gezeigt, beschleunigt der Fahrer noch mit etwa  $1,3 \text{ m/s}^2$  während das OuT nach einer Rollphase und der Mindestverzögerung von  $-0,5 \text{ m/s}^2$  entsprechend der Verhaltensplanung (siehe Kapitel 4.4.9) bereits mit  $-0,7 \text{ m/s}^2$  für die Haltestelle verzögert. Die Bahn fährt zu diesem Zeitpunkt mit  $41 \text{ km/h}$  und ist etwa  $76 \text{ m}$  von der Haltestelle entfernt.

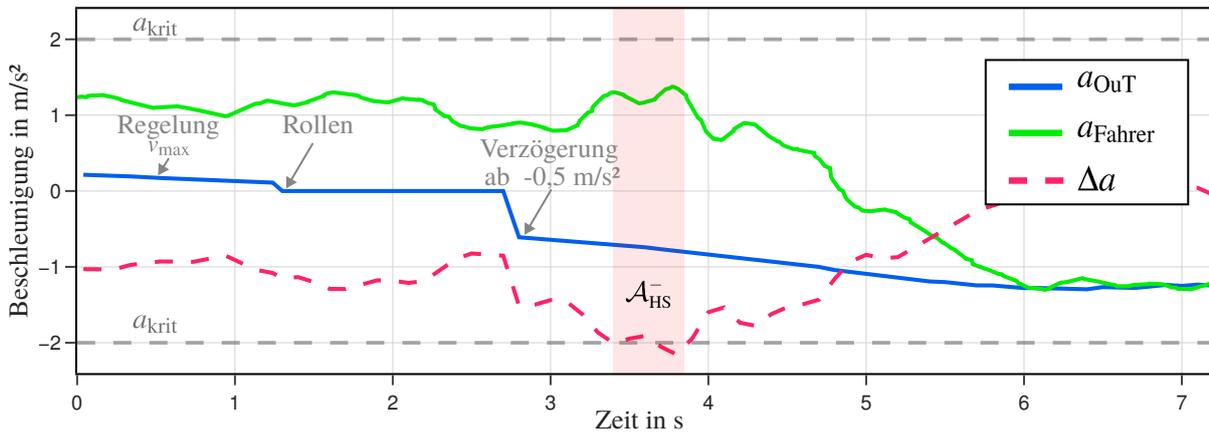


Abbildung 5-10: Beschleunigungsverlauf der einzigen, falsch positiv identifizierten  $\mathcal{A}_{\text{HS}}^-$ .

Der Fahrer wechselt innerhalb von ca. 2 s von der Beschleunigung zu einer Verzögerung von etwa  $-1,5 \text{ m/s}^2$  und beendet somit die Abweichung. Das Szenario zeigt, dass trotz des bezogen auf die Dynamik der Bahn hohen Schwellwertes  $\Delta a_{\text{krit}} = 2,0 \text{ m/s}^2$  Falsch-Positive aufgrund der Fahrweisen nicht ausgeschlossen werden können.

### 5.2.1 $\mathcal{A}_{\text{HS}}^-$ Teilevaluation

Es sind keine Abweichungen identifiziert, die auf ein Fehlverhalten des OuT im Sinne der  $\mathcal{A}^-$  auf eine zu starke Bremsung des OuT zurückzuführen sind. Da Haltestellen über auf dem Boden markierte und in der Karte hinterlegte Haltelinien verfügen, gibt es bspw. keine falsch positiven Abweichungen aufgrund unterschiedlicher Haltepunkte wie bei den LSA. Vorbehaltlich der  $\mathcal{A}^+$  kann die einfache karten- und fahrauftragsbasierte Berücksichtigung der Haltestellen als plausibilisierter Lösungsweg betrachtet werden.

## 5.3 $\mathcal{A}^-$ Höchstgeschwindigkeit

Nachfolgend werden die 297 identifizierten  $\mathcal{A}_{v_{\max}}^-$  analysiert, bei denen das OuT um mindestens  $a_{\text{krit}} = 2,0 \text{ m/s}^2$  stärker verzögert hat als der menschliche Fahrer.

### 5.3.1 $\mathcal{A}_{v_{\max}}^-$ Makroskopische Betrachtung

Bei allen identifizierten Abweichungen plant das OuT mit  $a_{\text{OuT}} < -1,0 \text{ m/s}^2$  zu verzögern. Entsprechend der Verhaltensplanung aus Kapitel 4.4.10 ist die Regelung für die zur Position der Straßenbahn gültigen Höchstgeschwindigkeit jedoch auf  $-1,0 \text{ m/s}^2$  begrenzt. Folglich handelt es sich bei allen Abweichungen um solche, die aufgrund einer nachfolgenden Begrenzung der Höchstgeschwindigkeit auftreten. Wie nachfolgend links in Abb. 5-11 (a) die eCDF der Distanzen bei Auftreten der  $\mathcal{A}_{v_{\max}}^-$  zeigt, treten alle Abweichungen maximal 26,5 m vor einer anstehenden Geschwindigkeitsregelung auf. Dabei handelt es sich bei allen anstehenden Geschwindigkeitsregelungen um eine Reduktion der Höchstgeschwindigkeit. Durch die Einfärbung der eCDF nach der Differenz zwischen aktueller und ab der Geschwindigkeitsregelungen erlaubter Höchstgeschwindigkeit wird deutlich, dass mit sinkender Distanz auch der Unterschied der Geschwindigkeit abnimmt. In Verbindung mit dem in Abb. 5-11 (b) rechts dargestellten Verhalten der menschlichen Fahrer und deren Bremsen mit  $a_{\text{Fahrer}} < 0 \text{ m/s}^2$  in etwa 72 % der Fälle, lässt vermuten, dass die menschlichen Fahrer in einigen wenigen Fällen zu spät auf eine anstehende Geschwindigkeitsregelung reagieren.

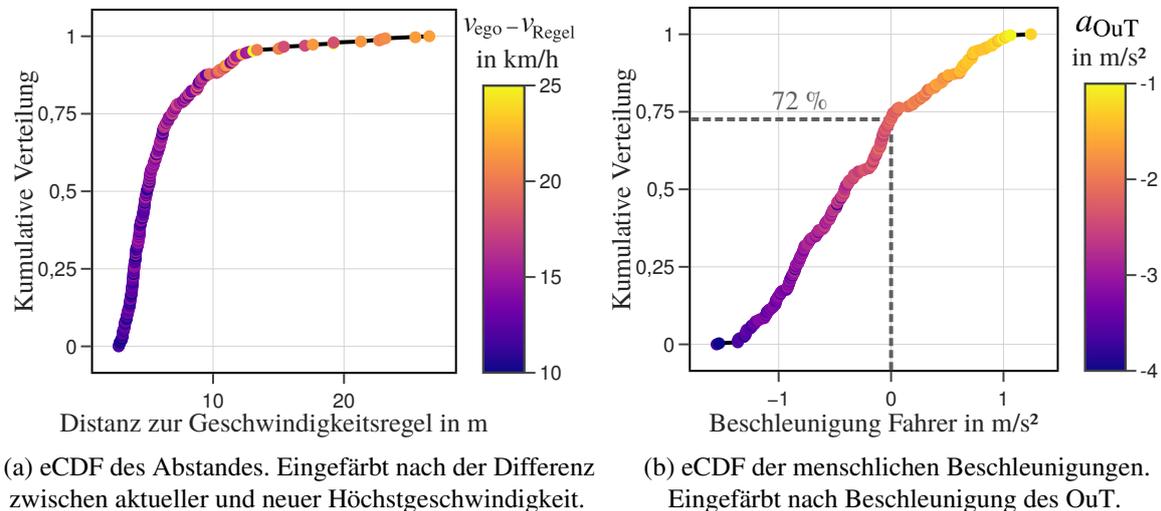


Abbildung 5-11: eCDF aller 297  $\mathcal{A}_{v_{\max}}^-$ .

Weiterhin geht aus Abb. 5-11 (b) hervor, dass es eine Korrelation zwischen dem Verhalten des Menschen sowie des OuT gibt. Je stärker das System bremst, desto stärker bremst bzw. weniger stark beschleunigt auch der menschliche Fahrer. Daher wird nachfolgende Hypothese zum

Verhalten der menschlichen Fahrer aufgestellt und mikroskopisch anhand einzelner Messfahrten für die Extremfälle  $a_{\text{Fahrer}} < -1,0 \text{ m/s}^2$  und  $a_{\text{Fahrer}} > 0,5 \text{ m/s}^2$  untersucht:

**Hypothese 1 ( $H_{v_{\max} 1}$ ):** Menschliche Fahrer bremsen vereinzelt für eine anstehende Beschränkung der Geschwindigkeit zu spät.

Darüber hinaus zeigt die obige Abb. 5-11 (b), dass in 28 % der Fälle der Fahrer noch beschleunigt während das OuT bereits verzögert. Sofern  $H_{v_{\max} 1}$  verifiziert werden kann, ist zu vermuten, dass auch einige dieser Abweichungen mit kleinen Beschleunigungen auf das Verhalten der menschlichen Fahrer zurückgeführt werden können. Jedoch sind auch andere Ursachen wie eine systematische Abweichung einer einzelnen Stelle denkbar. Dazu ist nachfolgend in Abb. 5-12 die geplante Beschleunigung des OuT über der vom Fahrer durchgeführten Beschleunigung dargestellt. Die verschiedenen Geschwindigkeitsregelungen sind dabei farblich markiert.

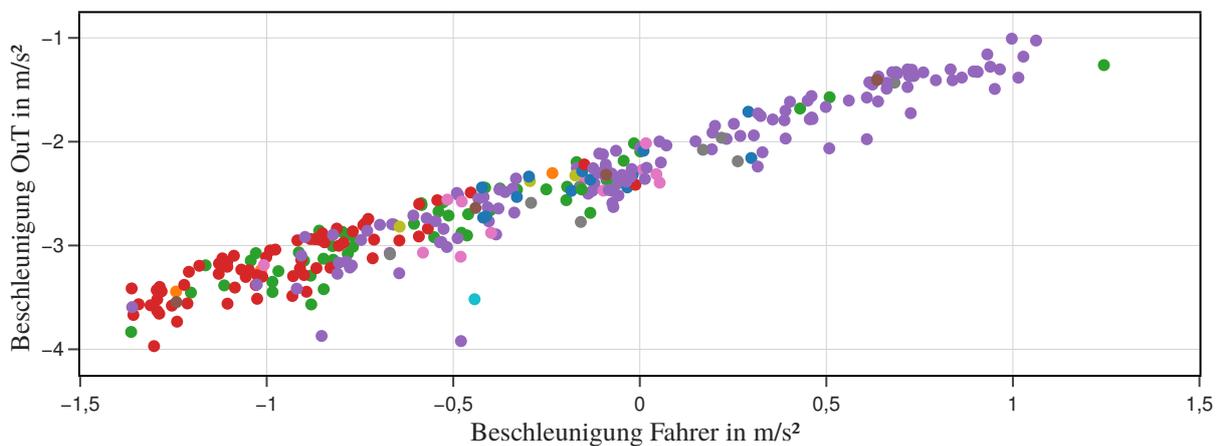


Abbildung 5-12: Beschleunigung des OuT vs. Beschleunigung des Fahrers aller  $\mathcal{A}_{v_{\max}}^-$ . Unterschiedliche bevorstehende Regelpunkte sind farblich markiert.

Insbesondere die mit ● markierte Geschwindigkeitsregelung weist hohe Beschleunigungen des Fahrers auf, was auf einen lokalen Fehler oder eine Besonderheit hindeutet, weshalb Messfahrten dieser Abweichungen nachfolgend mikroskopisch betrachtet werden und folgende Hypothese aufgestellt wird:

**Hypothese 2 ( $H_{v_{\max} 2}$ ):** Die Geschwindigkeitsregel ● ist inkorrekt oder wird vom OuT falsch berücksichtigt.

Die mit ● markierte Geschwindigkeitsregel weist durch die gleichzeitig starke Verzögerung des OuT sowie mehrheitlich auch des Fahrers darauf hin, dass  $H_{v_{\max} 1}$  insbesondere auch für bestimmte Stellen gilt, weshalb zusätzlich vermehrt Messfahrten zu dieser Abweichungen mikroskopisch betrachtet werden.

### 5.3.2 $\mathcal{A}_{v_{\max}}^-$ Mikroskopische Betrachtung

Für die mit ● gekennzeichnete Geschwindigkeitsregel wurde in allen 30 betrachteten Fällen sowie in weiteren 15 ausgewählten Extremfällen mit  $a_{\text{Fahrer}} < -1,0 \text{ m/s}^2$  und  $a_{\text{Fahrer}} > 0,5 \text{ m/s}^2$  festgestellt, dass der Fahrer bei Passieren der neuen Geschwindigkeitsregel zu schnell war. In den betrachteten Fällen betrug die Abweichung 9–21 km/h beim Passieren der Geschwindigkeitsregel, wobei in allen Fällen innerhalb kurzer Zeit nach dem Passieren die Geschwindigkeit auf den erlaubten Wert reduziert wurde. So traten bspw. 8 der 15 betrachteten Fälle sowie alle mit ● markierten Regeln aufgrund einer anstehenden Reduzierung auf 15 km/h an Einmündungen mit Weichen auf. In allen Fällen fuhren die Fahrer in der Kurve der Einmündung etwa 15 km/h. Das zugehörige Schild war jedoch bis zu 25 m vor Beginn der Kurve. Die Nullhypothese  $\mathbf{H}_{\max}^0 \mathbf{1}$ , dass Fahrer für eine Beschränkung stets rechtzeitig reagieren, ist somit falsifiziert und damit die oben aufgestellte Gegenhypothese bezüglich zu spätem Bremsen verifiziert. Zusätzlich wurde ein Fall identifiziert, in dem der Fahrer nochmal stark beschleunigt, um über eine F4 anzeigende LSA kurz hinter der Beschränkung zu fahren. Dieser Fall ist in der bereits gezeigten Abb. 5-11 (b) als Ausreißer oben rechts zu erkennen.

Weiterhin sind 83 Vorbeifahrten an der Geschwindigkeitsregel ● mikroskopisch untersucht worden. Bei dieser Regel handelt es sich um eine Beschränkung auf 30 km/h aufgrund einer langfristigen Baustelle an einem Haus und infolgedessen einer Umleitung des Fahrstreifens für Kraftfahrzeuge auf den eigentlich für die Straßenbahn reservierten besonderen Bahnkörper an dieser Stelle. Die Szenerie ist in Anhang B.3 gezeigt. Zeitlich betrachtet, fährt der Fahrer in den ersten 26 Abweichungen mit bis zu 12 km/h zu schnell. In jedem dieser Fälle war kein Kraftfahrzeug in diesem Bereich. Diese 26 Abweichungen erstrecken sich über einen Zeitraum von acht Monaten, in denen in Summe 98 Messfahrten an dieser Stelle aufgezeichnet sind. Für die restlichen 57 betrachteten  $\mathcal{A}_{v_{\max}}^-$  an dieser Stelle wurde jedoch festgestellt, dass die Umleitung wieder rückgängig gemacht und damit auch die Beschränkung auf 30 km/h entfernt worden ist. Da diese Arbeit nicht in die Abläufe des Nahverkehrsbaus integriert ist, wurde diese Änderung fälschlicherweise nicht in der im Rahmen der Referenzimplementierung erstellten Karte berücksichtigt. Das geplante Verhalten des OuT ist somit an dieser Stelle in Abhängigkeit des Zeitraums falsch. Die zugehörige Nullhypothese  $\mathbf{H}_{\max}^0 \mathbf{2}$  ist somit falsifiziert und die oben aufgestellte Gegenhypothese bezüglich inkorrekt gesetzter Geschwindigkeitsregel verifiziert.

### 5.3.3 $\mathcal{A}_{v_{\max}}^-$ Teilevaluation

Der größte Vorteil der kartenbasierten Bestimmung der gültigen Geschwindigkeitsregelung gegenüber der Alternative durch eine kamerabasierte Detektion der Beschilderung ist die Robustheit. Die kartenbasierte Bestimmung ist im Gegensatz zur Kamera unabhängig von Einflüssen durch Witterung, Gegenlicht, Tageszeiten, Manipulationen sowie einer aufwendigen Validierung einer maschinell gelernten Lösung, wie sie auch bereits für die Detektion des Signalzustandes von LSA im vorherigen Kapitel angeführt sind.

Als Nachteil ist jedoch der erforderliche Aufwand und Abhängigkeit für Änderungen gegenüber einer kamerabasierten Detektion zu nennen, wie es in der mikroskopischen Betrachtung anhand der ● Geschwindigkeitsregelung gezeigt wurde. Da jedoch die Festlegung der Geschwindigkeit in Verantwortung des Nahverkehrsbetriebes liegt oder dieser von anderen Stellen angewiesen wird, ist die Umsetzung von Änderungen in der Karte genauso in Prozesse integrierbar wie physische Änderungen der Beschilderungen. Von den in Summe 128 mikroskopisch betrachteten Fällen handelt es sich einerseits um einen Fehler in der Datengrundlage und sonst um eine zu späte Reaktion des Fahrers auf eine anstehende Geschwindigkeitsregelung. Die Möglichkeit aufgrund der genannten Motivatoren wie beschränktes Einsatzgebiet, Verantwortung in Hand des Nahverkehrsbetriebes etc. kartenbasiert die Geschwindigkeit zu bestimmen, wird daher als plausibilisiert bewertet.

Entsprechend der Verhaltensplanung (siehe Kapitel 4.4.10 & 4.4.11) ist die bestimmte Beschleunigung für nachfolgende Geschwindigkeitsänderungen  $a_{\text{soll},v_{\text{max,flg}}}$  nur auf die Dynamik der Straßenbahn mit  $-4,0 \text{ m/s}^2$  beschränkt. Durch die auf den Abstand und die Differenz zwischen Ist- und nachfolgender Soll-Geschwindigkeit basierende Bestimmung von  $a_{\text{soll},v_{\text{max,flg}}}$ , ist die Verzögerung des OuT auch bei kleinen Abständen bereits bei geringen Geschwindigkeitsabweichungen hoch. Einerseits erschwert dies die Anwendung von *Silent Testing* und würde bei einer tatsächlichen Umsetzung einer solch starken Verzögerung einer Gefahrenbremsung entsprechen, welche das Risiko für Auffahr- sowie Sturzunfälle innerhalb der Straßenbahn erhöht. Andererseits geriete OuT als eingreifende Automatisierung anstatt als Schattensystem durch frühes Bremsen nicht in ein solches vom Fahrer aufgezwungenes Szenario. Aufgrund der Risiken durch starke Verzögerungen sollte dennoch die Verzögerung des OuT für eine nachfolgende Geschwindigkeitsregelung ähnlich der Regelung auf die aktuelle erlaubte Geschwindigkeit (siehe Kapitel 4.4.10) begrenzt werden.

Für die Anwendung von *Silent Testing* zeigt sich weiterhin, dass wie grundsätzlich bei der Anwendung von *Silent Testing* zu erwarten auch der menschliche Fahrer Fehlverhalten zeigt. Aufgrund des Vergleiches mit  $\Delta a$  kommt es daher zu falsch positiven Abweichungen. Um die Anzahl dieser zu reduzieren, sind weitere Filter wie eine erlaubte Abweichung von  $\Delta a$  in Abhängigkeit der Distanz zur Geschwindigkeitsregelung oder eine Berücksichtigung der nachfolgenden Geschwindigkeit des Fahrzeugs denkbar. Die Reduzierung der falsch positiven Abweichungen ist zwar nicht zwingend erforderlich, aufgrund der Vielzahl erschweren diese jedoch die mikroskopische Betrachtung aller  $\mathcal{A}$ .

## 5.4 $\mathcal{A}^-$ Objekte

Im Rahmen der mit der Referenzimplementierung ausgewerteten Messdaten sind 7.925  $\mathcal{A}_0^-$  identifiziert, bei denen das OuT um mindestens  $a_{\text{krit}} = 2,0 \text{ m/s}^2$  stärker verzögert hat als der

menschliche Fahrer. Damit treten die  $\mathcal{A}_O^-$  häufiger auf, als alle anderen Kategorien an  $\mathcal{A}^-$  sowie  $\mathcal{A}^+$  zusammen. Auch wenn die hohe Anzahl an Abweichungen auf Herausforderungen der Straßenbahnautomatisierung oder Unzulänglichkeiten der Referenzimplementierung hinweisen, verhindern sie angesichts ihrer Vielzahl eine mikroskopische Betrachtung aller Abweichungen aufgrund des damit verbundenen Aufwandes.

### 5.4.1 $\mathcal{A}_O^-$ Makroskopische Betrachtung

Für die makroskopische Betrachtung werden aufgrund der Vielzahl der  $\mathcal{A}_O^-$  nachfolgend in verschiedenen Abschnitten Gemeinsamkeiten sowie Extrema identifiziert, um Stellvertreter für die mikroskopische Betrachtung zu identifizieren und so systematische Herausforderungen oder Unzulänglichkeiten aufzudecken.

#### Makroskopische Betrachtung der Lebensdauer von Objekten

Nachfolgend wird die Lebensdauer der Objekte zur Einordnung der Abweichungen genutzt. Die Lebensdauer entspricht dem Beobachtungszeitraum eines jeweiligen Objektes im Rahmen der zeitlichen Verfolgung, also des implementierten Trackings. Ein Objekt, das bereits länger zeitlich verfolgt also getrackt wird, hat eine höhere Lebensdauer als ein Objekt, das bspw. erst einmalig erkannt worden ist. Insbesondere Phantomobjekte, also falsch positive Objektdetektionen bspw. durch Mehrfach- oder Bodenreflexionen, bestehen aufgrund von Perspektivwechsel durch Eigen- oder Objektbewegung etc. häufig nur kurzzeitig. Die Lebensdauer ist somit ein Indikator für die tatsächliche Existenz und Robustheit der Objekte. Andererseits können auch Objekte mit einer Lebensdauer von 0 s aufgrund von Verdeckungen und oder Tracking Fehlern (bspw. ein reales Objekt erzeugt fälschlich immer wieder ein neues  $\mathcal{O}_{\text{track}}$ ) real existierende Objekte und somit auch Hindernisse darstellen.

Abb. 5-13 (a) nachfolgend links stellt die  $a_{\text{OuT}}$  als eCDF also die Verteilung der geplanten Beschleunigung des OuT bei Eintreten der jeweiligen  $\mathcal{A}_O^-$  dar. Dabei ist die Lebensdauer der Objekte farblich in der eCDF markiert. Aus der Abbildung geht hervor, dass in 64 % der Abweichungen das OuT plant mit der maximalen Verzögerung<sup>176</sup> von  $-4,0 \text{ m/s}^2$  zu bremsen. In der Mehrheit der Abweichungen geht das OuT somit von einer Notsituation aus, deren Auslöser es aufgrund der Stärke der Bremsung (und des damit verbundenen Risikos bezüglich Sturz- und Auffahrunfällen) sowie des häufigen Auftretens näher zu betrachten gilt. In Abb. 5-13 (b) sind dazu nachfolgend rechts die Lebensdauern der Objekte bei Eintreten der  $\mathcal{A}_O^-$  als eCDF dargestellt. Dabei wird nach der Stärke der vom OuT geplanten Verzögerung unterschieden. In — sind die 64 % Abweichungen mit maximaler Verzögerung sowie in — die restlichen 36 % aller Fälle dargestellt. Die Abbildung zeigt, dass Objekte bei Abweichungen mit der maximalen Verzögerung grundsätzlich kürzere Lebensdauern haben, jedoch insbesondere die 22 % mit einer Lebensdauer von 0 s lassen auf eine Reaktion in Folge eines Phantomobjektes schließen.

<sup>176</sup> Beschränkung der Dynamik, siehe Kapitel 4.4.11.

Daher wird nachfolgende Hypothese formuliert und einzelne Messreihen als Stellvertreter mikroskopisch untersucht:

**Hypothese 1 ( $H_{O1}$ ):** Ein Teil der Abweichungen durch Objekte ist auf plötzlich auftretende Phantomobjekte zurückzuführen.

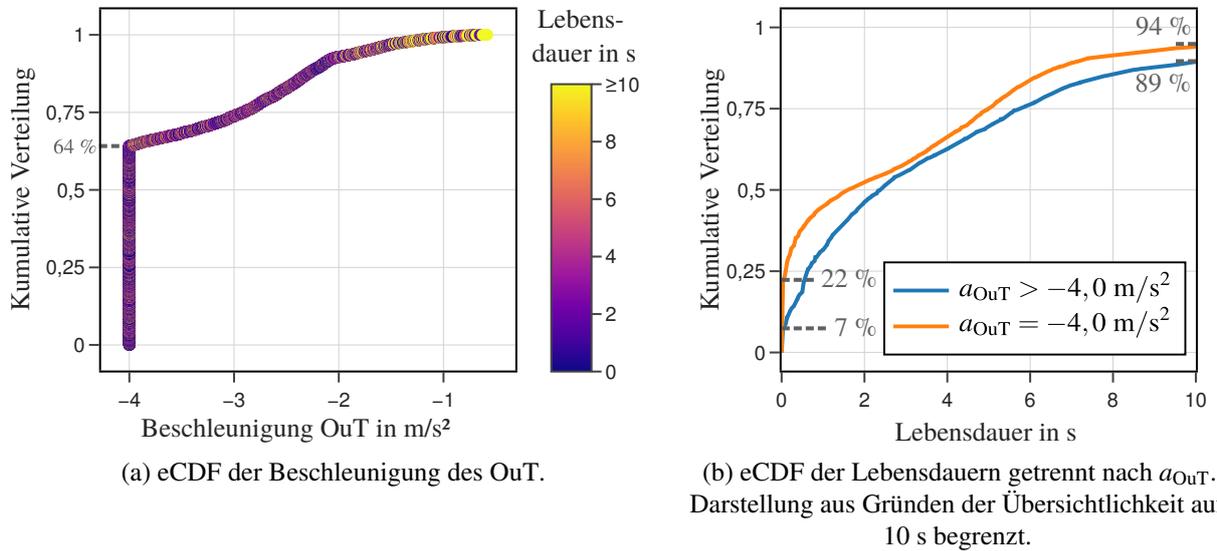


Abbildung 5-13: Einordnung der Beschleunigungen bezüglich identifizierter  $\mathcal{A}_{\bar{O}}$ . Einfärbung nach Lebensdauer der Objekte bei Beginn der  $\mathcal{A}_{\bar{O}}$ .

Die rechts in Abb. 5-13 (b) dargestellten eCDF sind zur Übersichtlichkeit auf 10 s begrenzt. Daraus geht jedoch hervor, dass bei etwa 6 % mit maximaler Verzögerung bzw. 11 % der restlichen Fälle die zugehörigen Objekte bereits mindestens 10 s existieren. Die längste Lebensdauer eines Objektes bei Eintreten einer  $\mathcal{A}_{\bar{O}}$  beträgt 81 s. Dabei könnte es sich bspw. um Objekte nach langer Ego-Standzeit aber auch ggf. fälschlicher Einordnung als Hindernis nach gemeinsamer Parallelfahrt handeln. Daher werden mikroskopisch einzelne Messreihen mit Objekten mit länger Lebensdauer betrachtet, um Gründe für die vermeintlich falsche Einordnung als Hindernis aufzudecken.

**Hypothese 2 ( $H_{O2}$ ):** Objekte, die sich über mehrere Sekunden mit der Bahn mit bewegen, werden fälschlicherweise als Hindernis erkannt.

### Makroskopische Betrachtung der Höhe von Objekten

Zur weiteren Untersuchung von Gemeinsamkeiten ist nachfolgend in Abb. 5-14 die Objekthöhe (Höhe des  $\mathcal{O}_{\text{track}}$ , nicht Höhe über Boden) als eCDF und Balkendiagramm dargestellt. Wie zuvor wird weiterhin unterschieden, ob das OuT plant mit einer maximalen oder geringeren Verzögerung zu bremsen. Zusätzlich ist nachfolgend durch eine Farbabstufung unterschieden, ob das auslösende Objekt zum Zeitpunkt der Überschreitung von  $a_{\text{krit}}$  in Bewegung war oder nicht. Dabei geht aus Abb. 5-14 hervor, dass sich die Mehrheit der Objekte nicht bewegen.

Insbesondere für  $\mathcal{A}_O^-$  mit maximaler Verzögerung zeigt die Verteilung einen signifikanten Knick bei etwa 0,6 m. Die Mehrheit der Objekte die kleiner sind, bewegen sich nicht. Eine mögliche Ursache für niedrige, sich nicht bewegende Objekte sind falsch positive Detektionen aufgrund fehlgeschlagener Filterung der Bodenreflexionen.

**Hypothese 3 ( $H_{O3}$ ):** *Der genutzte Lidar Bodenfilter ist nicht ausreichend, um falsch positive Objektdetektionen zu verhindern.*

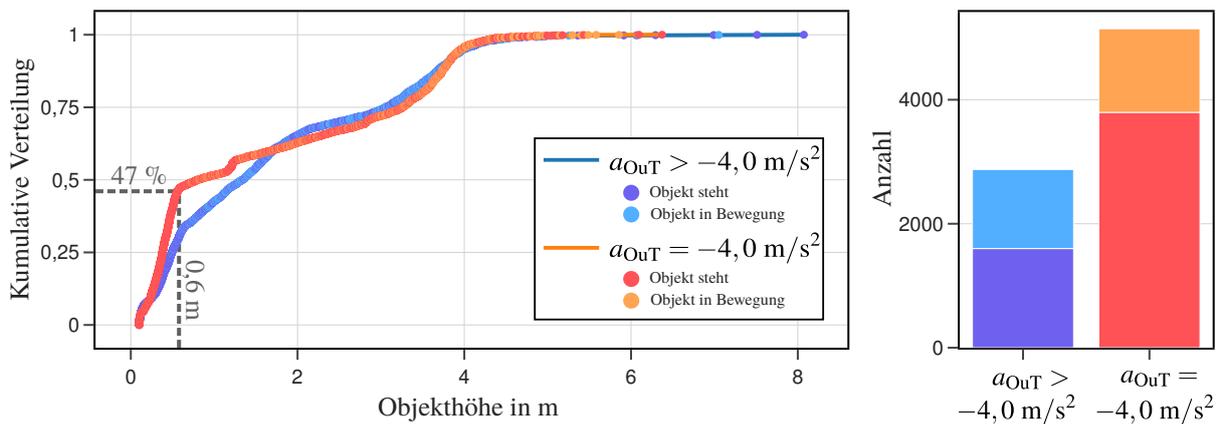


Abbildung 5-14: eCDF und Balkendiagramm der Objekthöhe. Farblich markiert ist der Bewegungszustand bei Eintreten der  $\mathcal{A}_O^-$ .

Weiterhin zeigt obige Abb. 5-14, dass es kurz vor 4 m Objekthöhe erneut einen Wechsel der Steigung gibt. Dies deutet an, dass es verhältnismäßig viele Objekte zwischen etwa 3,5–4,0 m gibt, die eine Abweichung auslösen. Eine gesonderte Betrachtung der Objekte in diesem Bereich zeigt, dass etwa 70 % der Objekte, bei Eintreten der  $\mathcal{A}_O^-$  in Bewegung waren. Insbesondere andere Straßenbahnen und Busse haben eine Höhe in diesem Bereich und Begegnen der Versuchsbahn häufig, womit die Änderung der Steigung begründet sein könnte. Daher wird nachfolgende Hypothese aufgestellt und einzelne Messreihen als Stellvertreter mikroskopisch untersucht:

**Hypothese 4 ( $H_{O4}$ ):** *Andere Straßenbahnen und Busse werden fälschlicherweise als Hindernis erkannt.*

Entsprechend dem in Kapitel 4.4.3 vorgestellten Lidar-Clustering werden Reflexionspunkte des Lidars oberhalb 4,0 m über Schienenoberkante in einem Vorfilter entfernt. Dennoch sind in der oben dargestellten Abb. 5-14 wenige Objekte mit Höhen bis 8,1 m vorhanden. Befindet sich ein Objekt bspw. neben dem Bahndamm und fängt damit unterhalb der Schienenhöhe an, so sind trotz Vorfilter Objekte  $> 4,0$  m möglich. Dies ist jedoch nicht hinreichend, damit ein solches Objekt, welches sich außerhalb der Gleise befindet, auch als Hindernis eingeordnet wird. Aus diesem Grund wird die Kombination von fehlerhaftem Clustering mehrerer Objekte als mögliche Ursache vermutet, wobei mindestens eines der realen Objekte tiefer als die Schienenoberkante liegt. Daher wird nachfolgende Hypothese aufgestellt sowie Messreihen mit einer eindeutigen Objekthöhe größer als 5,0 m mikroskopisch untersucht:

**Hypothese 5 (H<sub>5</sub>):** *Tiefer liegende Objekte mit einer Höhe größer als 4,0 m werden fälschlicherweise mit anderen Sensor Detektionen innerhalb des Fahrschlauches in einem Lidar-Cluster zusammengefasst und als Hindernis eingeordnet.*

### Makroskopische Betrachtung des Bodens unterhalb der Objekte

Zur weiteren Untersuchung möglicher Detektionen des Bodens werden die  $\mathcal{A}_{\bar{O}}$  nachfolgend bezüglich ihres Untergrundes untersucht, um bspw. systematisches Versagen des Lidar Bodenfilters aufzuzeigen oder auszuschließen. Dazu wird in die vier nachfolgenden Bodenkategorien unterschieden:

- **Gepflastert:** Alle straßenbündigen und besonderen Bahnkörper, die mit Asphalt, Steinen oder ähnlichem für die Nutzung (dauerhaft oder auch nur im Ausnahmefall) durch andere Verkehrsteilnehmer eben gepflastert sind.
- **Offen:** Unabhängige Bahnkörper mit offenem Gleisbett, bei dem die Bahnschwellen oder ähnliche Schienenunterstützung vollständig oder teilweise offen sichtbar sind.
- **Bedeckt:** Bahnkörper, die nicht gepflastert und nicht offen sind, werden als bedeckt bezeichnet. Dazu zählen bspw. Rasenflächen, bis zur Schienenkante aufgefüllter feiner Schotter sowie andere Bodendecker.
- **Bahnübergang (BÜ):** BÜ, die selbst einen anderen Untergrund aufweisen als die angrenzenden Bahnkörper, werden aufgrund des Wechsels gesondert betrachtet. Ausgenommen sind also bspw. Kreuzungen bei straßenbündigen Bahnkörpern.

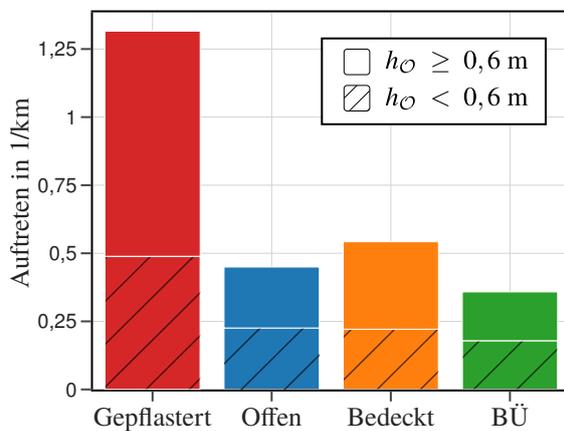
Beispiele für diese vier Bodenkategorien sind nachfolgend in Abb. 5-15 (b) rechts dargestellt. Die absolute Anzahl identifizierter  $\mathcal{A}_{\bar{O}}$  pro oben definierter Bodenkategorie ist in Tabelle 5-2 gegeben. Dabei wird der Untergrund unter dem Objekt und nicht der Untergrund unter der Straßenbahn zum Zeitpunkt des Auftretens der  $\mathcal{A}_{\bar{O}}$  betrachtet.

Tabelle 5-2: Absolute Anzahl  $\mathcal{A}_{\bar{O}}$  pro Bodenkategorie.

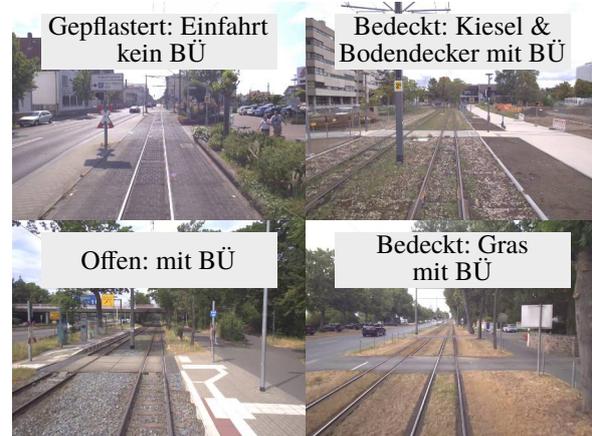
	<b>Gepflastert</b>	<b>Offen</b>	<b>Bedeckt</b>	<b>BÜ</b>
$\mathcal{A}_{\bar{O}}$	6.396	749	814	62

Zwar treten besonders viele  $\mathcal{A}_{\bar{O}}$  auf gepflastertem Untergrund auf, jedoch sind die Bodenkategorien unterschiedlich häufig im Straßenbahnnetz und auch in den gefahrenen Linien der Messdaten vertreten. Daher sind nachfolgend in Abb. 5-15 (a) die Abweichungen auf die im Datensatz absolvierte Gesamtstrecke der jeweiligen Bodenkategorie normiert. Zusätzlich sind entsprechend dem Knick der oben dargestellten eCDF mit  Objekte mit einer Höhe  $h_{\bar{O}} < 0,6$  m markiert. Für keine Bodenkategorie ist eine Überrepräsentation dieser kleinen Objekte angegeben, die auf ein systematisches Versagen des Bodenfilters für eine Bodenkategorie hingewiesen hätte.

Die auf die jeweilige Gesamtstrecke normierte Mehrheit der Abweichungen tritt unabhängig der Objekthöhe auf gepflastertem Untergrund auf. Dies entspricht den Erwartungen, da es auf gepflastertem Untergrund durch den häufig geteilten Verkehrsraum auch zu mehr Begegnungen mit realen Objekten und somit zu möglichen Fehleinschätzungen eines realen Objektes als Hindernis und damit zu  $\mathcal{A}_O^-$  kommt.



(a) Auftreten der  $\mathcal{A}_O^-$  auf die Gesamtstrecke der jeweiligen Bodenkategorie normiert.



(b) Beispiele für die vier Bodenkategorien.

Abbildung 5-15: Verteilung der  $\mathcal{A}_O^-$  auf vier Bodenkategorien.

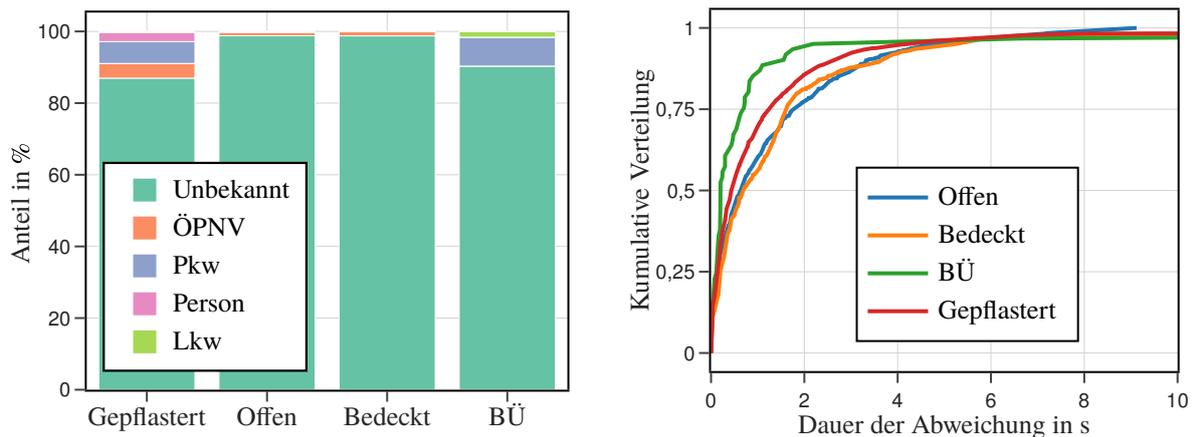
Da durch die Kategorie BÜ offizielle Aufenthaltsräume anderer Verkehrsteilnehmer ausgenommen sind, sollten im Umkehrschluss insbesondere das *offene* sowie das *bedeckte* Gleis signifikant weniger  $\mathcal{A}_O^-$  aufweisen. Dies ist zwar wie in Abb. 5-15 (a) links dargestellt auch der Fall, andererseits sind 0,45 Abweichungen pro gefahrenem Kilometer auf *offenem* Gleis sowie 0,54 Abweichungen pro gefahrenem Kilometer auf *bedecktem* Gleis absolut betrachtet bereits mehr Objekte als für diese Untergründe zu erwarten ist. Aufgrund der Abtrennung vom restlichen Verkehrsraum ist ein Auftreten von realen und fälschlicherweise als Hindernis klassifizierten Objekten mit so kurzen räumlichen Abständen von etwa 2 km unwahrscheinlich. Dies weist darauf hin, dass insbesondere für *offenes* sowie *bedecktes* Gleis Objekte als Hindernisse eingeordnet werden, die in der Realität kein Verkehrsteilnehmer sind.

### Makroskopische Betrachtung der Klassen der Objekte

Zur näheren Untersuchung, ob es sich nicht um Verkehrsteilnehmer handelt, ist daher nachfolgend links in Abb. 5-16 (a) die prozentuale Verteilung der kamerabasierten Klassifizierung (siehe Kapitel 4.4.4) für die identifizierten  $\mathcal{A}_O^-$  pro Bodenkategorie dargestellt. Für jede Bodenkategorie ist die Mehrheit der Objektklassen *unbekannt*. Einerseits könnte dies auf detektierte Objekte hinweisen, die in der Realität keiner der sechs definierten Objektklassen entspricht, andererseits auch auf ein grundsätzliches Defizit der umgesetzten kamerabasierten Klassifikation. Aus diesem Grund ist in Anhang B.4 die Klassifikation von Objekten ohne Abweichung untersucht. Unter allen 31.159 Objekten, auf die ohne eine Abweichung reagiert wird, ist die häufigste Klasse

für 58 % aller Objekte ebenfalls *unbekannt*. Werden dabei jedoch nur Objekte betrachtet, die mindestens 1 s existieren, um  $\mathcal{A}^-$  potenzieller Phantomobjekte außen vorzulassen, sind nur 28 % der Objekte *unbekannt*.

Die kamerabasierte Klassifikation weist somit zwar Schwächen auf, diese erklären jedoch verhältnismäßig nicht den nachfolgend in Abb. 5-16 (a) gezeigten hohen Anteil an *unbekannt* unter den  $\mathcal{A}_O^-$ . Insbesondere die Bodenkategorien *offen* sowie *bedeckt* weisen jedoch nahezu ausschließlich *unbekannte* Objekte auf. Dies spricht für eine Vielzahl an falsch positiv detektierten Objekten, die in der Realität keine Verkehrsteilnehmer sind.



(a) Absolutes Auftreten der  $\mathcal{A}_O^-$  in der jeweiligen Bodenkategorie. Unterteilung in identifizierte Klassen.

(b) eCDF der Dauer der  $\mathcal{A}_O^-$ . Aufgeteilt in die vier Bodenkategorien. Begrenzt auf 10 s.

Abbildung 5-16: Einfluss des Untergrundes auf Klassifizierung und Dauer der Abweichung.

Durch den nicht-ebenen Untergrund des *offenen* und *bedeckten* Gleises kann insbesondere ein Versagen des in Kapitel 4.4.3 beschriebenen Bodenfilters nicht als Ursache ausgeschlossen werden. Sporadisch nicht korrekt gefilterte Lidarpunkte des Bodens müssten durch die Eigenbewegung und den damit verbundenen Perspektivwechsel jedoch von kurzer Dauer sein. Aus diesem Grund sind nachfolgend rechts in Abb. 5-16 (b) die eCDF der Dauer der  $\mathcal{A}_O^-$  nach den vier Bodenkategorien getrennt dargestellt. Weder das *offene* noch das *bedeckte* Gleis weisen im Vergleich mit dem *gepflasterten* Boden besonders kurz andauernde Abweichungen auf. Im Gegenteil, aufgrund der üblicherweise höheren Geschwindigkeiten bei offenem Gleis wären dort insbesondere Abweichungen mit einer kurzen Dauer zu erwarten, dies zeigt sich jedoch nicht.

Aufgrund der vergleichsweise kurzen Dauern der  $\mathcal{A}_O^-$  an *BÜ* sowie einer Analyse des Bewegungszustands der entsprechenden Objekte, die offenbart, dass diese in etwa 90 % der Fälle keine Bewegung aufweisen, wird der Übergang der Bodenkategorien als mögliche Ursache betrachtet. Davon abgeleitet wird nachfolgende Hypothese formuliert sowie aufgrund der geringen Gesamtanzahl einzelne Messreihen als Stellvertreter mikroskopisch untersucht:

**Hypothese 6 ( $H_{O6}$ ):** An Bahnübergängen versagt das Bodenfilter durch den Wechsel des Untergrundes.

Die eCDF in Abb. 5-16 (b) sind auf 10 s beschränkt. Weniger als 1 % aller  $\mathcal{A}_{\bar{O}}$  dauern jedoch länger als 10 s. Die längste Abweichung dauert 65 s. Da Abweichungen nur bei Bewegung der Bahn berücksichtigt werden, müsste sich ein Objekt für eine solche Dauer mit der Bahn bewegen und dabei dauerhaft als Hindernis eingeordnet werden. Alle diese Objekte verursachen dauerhaft eine maximale Verzögerung von  $a_{\text{Out}} = -4,0 \text{ m/s}^2$ . Auch wenn ein solches Szenario mit einem realen Objekt theoretisch möglich ist, ist es aufgrund anhaltender Kritikalität und ausbleibender Reaktion des Fahrers unwahrscheinlich. Eine mögliche Ursache könnten Störungen des Sensors sein, weshalb folgende Hypothese formuliert und zugehörige Messdaten im nachfolgenden Kapitel mikroskopisch betrachtet werden:

**Hypothese 7 ( $H_{\bar{O}7}$ ):** *Über mehrere Sekunden andauernde Sensorfehler führen zu fehlerhaften Detektionen und verursachen Verzögerungen mit  $a_{\text{Out}} = -4,0 \text{ m/s}^2$ .*

Neben der Betrachtung des Bewegungszustandes für  $B\ddot{U}$  ergibt sich für die anderen Kategorien, dass sich etwa 91 % auf *offenem* Gleis, 88 % auf *bedecktem* sowie 61 % aller Objekte auf *gepflastertem* Boden während der Abweichung nicht bewegen. Für das *offene* und *bedeckte* Gleis ist dies aufgrund des abgetrennten Verkehrsraums wie oben beschrieben zu erwarten und ist als weiteres Indiz dem Verdacht zuzuordnen, dass es sich bei den Objekten nicht um reale Verkehrsteilnehmer handelt. Neben dem Boden befinden sich insbesondere Vegetation (Sträucher, Gräser etc.) sowie Infrastrukturelemente (Oberleitungsmasten, Schilder, LSA etc.) als potenziell falsch identifizierte stehende Objekte auf *offenem* oder *bedecktem* Boden. Daher werden diesbezüglich zwei Hypothesen aufgestellt. Für die Auswahl von Messreihen für die zugehörige mikroskopische Verifikation werden im weiteren Verlauf dieses Kapitels im Rahmen der Betrachtung des Fahrerverhaltens einzelne Aufnahmen mit stehenden Objekten ausgewählt. Dies begründet sich erneut damit, dass aufgrund der Vielzahl von 749  $\mathcal{A}_{\bar{O}}$  bei *offenem* Gleis und 814 bei *bedecktem* Gleis einer mikroskopische Betrachtung aller Abweichungen die Aufwände den Nutzen übersteigen. Für beide Bodenkategorien gilt, dass sich durch die exklusive Nutzung dieser Verkehrsräume durch die spurgebundene Straßenbahn die Infrastrukturelemente meist näher am Fahrschlauch befinden, da kein breiterer von Kraftfahrzeugen befahrbarer Fahrstreifen sowie ggf. Gehwege etc. erforderlich sind.

**Hypothese 8 ( $H_{\bar{O}8}$ ):** *Infrastrukturelemente werden auf offenem und bedecktem Boden fälschlicherweise als Hindernis erkannt.*

Aufgrund dieser ausschließlichen Nutzung dieses Verkehrsraumes durch die Straßenbahn und des grundsätzlich potenziell bewachsenen Bodens wird die Vegetation nur durch menschlichen Rückschnitt oder durch Vorbeifahrten der Straßenbahnen selbst beeinflusst. Letzteres ist durch die erforderliche Nähe zwischen Vegetation sowie Fahrzeug und damit Fahrschlauch eine mögliche Ursache für Abweichungen.

**Hypothese 9 ( $H_{\bar{O}9}$ ):** *Vegetation wird auf offenem und bedecktem Boden fälschlicherweise als Hindernis erkannt.*

Wie zuvor erwähnt, bewegen sich während der Abweichung nur 61 % aller Objekte auf *gepflastertem* Boden. Zudem zeigt obige Abb. 5-16 (a), dass auch auf *gepflastertem* Boden Objekte zwar mehrheitlich der Klasse *unbekannt* angehören, jedoch verglichen mit den anderen Bodenkategorien mehr Objekte zu den Klassen *Pkw*, *ÖPNV* sowie *Person* gehören. Aus diesen Beobachtungen wird ein Versagen der Absicht zum Kreuzen der Objekte als mögliche Ursache für die auftretenden Abweichungen betrachtet und als Hypothese formuliert:

**Hypothese 10 ( $H_{O10}$ ):** Die umgesetzte Erkennung von kreuzenden Objekten ist nicht ausreichend und insbesondere auf gepflastertem Untergrund werden kreuzende Verkehrsteilnehmer fälschlicherweise als Hindernis erkannt.

### Makroskopische Betrachtung des Fahrerverhaltens

Zur weiteren Einordnung möglicher Gründe für die Abweichungen wird nachfolgend das geplante Verhalten des OuT in Relation zum Fahrerverhalten betrachtet. Dies ermöglicht einerseits die Auswirkungen der Bestimmung von Abweichung mittels einfacher Schwellwertbetrachtung auf *Silent Testing* makroskopisch zu untersuchen, andererseits werden basierend auf möglichst gleichem und widersprüchlichem Verhalten Hypothesen gebildet und Messreihen für die mikroskopische Betrachtung ausgewählt.

Dazu ist nachfolgend in Abb. 5-17 die Beschleunigung des OuT  $a_{\text{OuT}}$  über der Beschleunigung des Fahrers  $a_{\text{Fahrer}}$  sowohl zum Beginn also bei Eintreten der Abweichung sowie zum Ende der Abweichung dargestellt. Da nur Abweichungen dargestellt sind, resultiert die diagonale Beschränkung der Punkteverteilung aus der Bedingung zum Schwellwert  $|a_{\text{OuT}} - a_{\text{Fahrer}}| > a_{\text{krit}} = 2,0 \text{ m/s}^2$ . Zusätzlich ist rechts die eCDF der  $a_{\text{OuT}}$  für die beiden Zeitpunkte dargestellt. Die Verteilungsfunktion ist gedreht, da alle drei Graphen die gleiche Ordinatenachse und Skalierung zur Darstellung von  $a_{\text{OuT}}$  aufweisen. Dabei entspricht die — eCDF der gedrehten Kurve, die bereits zu Beginn des Kapitels in Abb. 5-13 (a) dargestellt ist.

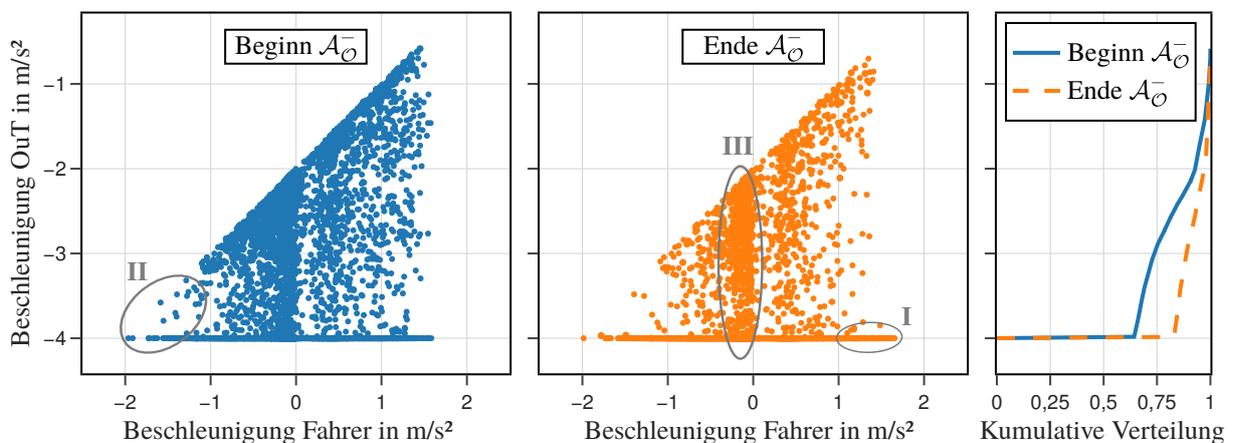


Abbildung 5-17:  $a_{\text{OuT}}$  über  $a_{\text{Fahrer}}$  aller  $\mathcal{A}_O^-$ . Links zu Beginn der Abweichung; Mitte zum Ende der Abweichung. Zusätzlich zeigt rechts die gedrehte eCDF der  $a_{\text{OuT}}$  die Verschiebung der Punkte an. Alle Ordinatenachsen sind gleich und stellen  $a_{\text{OuT}}$  dar.

Der Unterschied der beiden eCDF zeigt, dass die  $a_{\text{OuT}}$  sich über den Verlauf der  $\mathcal{A}_{\text{O}}^-$  zu stärkeren Verzögerungen verschieben. Dies ist ein weiteres Indiz für die oben aufgeführten Hypothesen  $\mathbf{H}_{\text{O}8}$  zur Infrastruktur sowie  $\mathbf{H}_{\text{O}9}$  zur Vegetation, da durch die Annäherung und letztendlich Überfahrt stationärer fälschlich detektierter Hindernisse insbesondere der Anteil mit maximaler Verzögerung  $a_{\text{OuT}} = -4,0 \text{ m/s}^2$  steigt. Dabei kommt es in dem mit I gekennzeichnetem Bereich zu starken Bremsreaktionen des OuT, während der Fahrer eindeutig beschleunigt. Da mit ● die Verteilung zum letztmaligen Auftreten der Abweichungen dargestellt wird, kann aufgrund der eingeschränkten Dynamik der Bahn davon ausgegangen werden, dass die Abweichung im nächsten Zeitschritt nur durch Ausbleiben des Hindernisses (Vorbeifahrt, Objekt aus Fahrschlauch etc.) und nicht durch eine bremsende und somit angleichende Reaktion des Fahrers beendet wird. Daher werden jeweils 30  $\mathcal{A}_{\text{O}}^-$  mit stationären Objekten auf *offenem* und *bedecktem* Boden aus diesem Bereich zur Verifikation von  $\mathbf{H}_{\text{O}8}$  und  $\mathbf{H}_{\text{O}9}$  verwendet.

In dem in Abb. 5-17 mit II gekennzeichnetem Bereich plant das OuT eine starke Verzögerung, während der Fahrer ebenfalls eindeutig, wenn auch um  $a_{\text{krit}}$  geringer verzögert. Durch die reine Bildung der Abweichung mittels Schwellwertbetrachtung können sich insbesondere für ein Szenario mit einer tatsächlich sprunghaft erforderlichen starken Bremsung Abweichungen in den Reaktionszeiten des OuT sowie Fahrers ergeben. Aus diesem Grund werden einzelne Messreihen aus diesem Bereich mikroskopisch betrachtet und als Hypothese ein Versagen der Erkennung von Abweichungen für solche Fälle formuliert:

**Hypothese 11 ( $\mathbf{H}_{\text{O}11}$ ):** *Für den Fall einer tatsächlich starken Verzögerung versagt die Erkennung von Abweichungen durch abweichende Reaktionszeiten von Fahrer und OuT.*

Sowohl für den Beginn (●) wie auch das Ende (●) der Abweichungen ist in dem mit III markiertem Bereich der obigen Abb. 5-17 eine Anhäufung von Punkten ersichtlich. In diesem Bereich lässt der menschliche Fahrer die Bahn unter Wirkung geringer Widerstandskräfte rollen. Insbesondere für den oberen Teil dieses Bereiches mit  $a_{\text{OuT}} \approx -2,0 \text{ m/s}^2$  ist als mögliche Ursache ein Abwarten und Beobachten realer Objekte durch den menschlichen Fahrer denkbar, während das OuT diese Objekte als Hindernis einstuft und auf diese reagiert. Daher wird nachfolgende Hypothese formuliert und einzelne Messreihen aus diesem Teil des Bereiches als Stellvertreter mikroskopisch untersucht:

**Hypothese 12 ( $\mathbf{H}_{\text{O}12}$ ):** *Im Vergleich mit dem menschlichen Fahrer reagiert das OuT bei noch nicht eindeutigem Verhalten von Objekten zu früh auf diese.*

### Makroskopische Betrachtung von $\mathcal{A}_{\text{O}}^-$ Hotspots

Zur abschließenden makroskopischen Betrachtung werden im Folgenden örtliche Positionen lokal häufig auftretender Abweichungen als sogenannte Hotspots bestimmt, um systematisch Orte mit Herausforderungen an die Automatisierung von Straßenbahnen oder örtlich wieder-

kehrende Unzulänglichkeiten der Referenzimplementierung aufzudecken. Dabei wird in zwei unterschiedliche Arten von Hotspots unterschieden:

- **Punktförmige Hotspots:** Durch örtliche Besonderheiten wie fälschlich als Hindernis erfasste Elemente der Infrastruktur oder Vegetation kommt es aufgrund des vermeintlich immer selben Objektes zu einer geringen räumlichen Verteilung der  $\mathcal{A}_{\bar{O}}$  im Rahmen der punktförmigen Hotspots.
- **Ausgedehnte Hotspots:** Durch örtliche Besonderheiten wie fälschlich als Hindernis erfasste kreuzende Verkehrsteilnehmer in Fußgängerzonen kommt es zwar wiederholt zu  $\mathcal{A}_{\bar{O}}$ , da diese jedoch nicht durch dasselbe Objekt verursacht werden, weisen die zugehörigen ausgedehnten Hotspots eine größere räumliche Verteilung auf.

Zur Bildung der Hotspots werden die  $\mathcal{A}_{\bar{O}}$  entsprechend ihrer Distanz zueinander gruppiert. Eine Gruppe wird gebildet, wenn die Distanz zwischen zwei Objekten entlang des Gleises (gegen oder mit der Fahrrichtung) weniger als  $d_{\text{hspot}}$  beträgt. Ein Objekt bzw. das zugehörige  $\mathcal{A}_{\bar{O}}$  wird einer bestehenden Gruppe zugeordnet, wenn es zumindest zu einem anderen Objekt der Gruppe eine Distanz geringer  $d_{\text{hspot}}$  entlang des Gleises aufweist. So sind auch *ausgedehnte* Hotspots möglich. Die Bestimmung der Distanz entlang des Gleises unterdrückt die Überbewertung und Bildung großer Hotspots durch unterschiedliche Auslöser in unterschiedliche Fahrrichtungen. Im Rahmen dieser ersten Umsetzung wurde als Schwellwert eine maximale Distanz von  $d_{\text{hspot}} = 3$  m gewählt, um einerseits räumliche Variationen von Objekten bspw. in Fußgängerzonen zu ermöglichen, andererseits aufgrund der Vielzahl der gesamtheitlich identifizierten  $\mathcal{A}_{\bar{O}}$  keine zu weit ausgedehnten fälschlichen Hotspots, basierend auf unterschiedlichen Auslösern zu generieren.

Es sind 635 Gruppen also Orte mit Anhäufungen identifiziert. Die größte Gruppe beinhaltet 340  $\mathcal{A}_{\bar{O}}$ , während etwa 36 % der gebildeten Gruppen nur aus zwei  $\mathcal{A}_{\bar{O}}$  bestehen und somit keinen Hotspot begründen. Auch sind 1.010 der in Summe insgesamt 7.925  $\mathcal{A}_{\bar{O}}$  nicht in der Nähe eines anderen Objektes und bilden somit keine Gruppe. Anzumerken ist, dass die Orte der Gruppen unterschiedlich häufig befahren sind. Das liegt zum einen daran, dass Knotenpunkte des Straßenbahnnetzes besonders häufig in den Messdaten vertreten sind und zum anderen am ungleichmäßigen Einsatz des Versuchsträgers auf verschiedenen Linien. Für einen Vergleich der Gruppen miteinander wird daher für jede Gruppe  $i$  ein normierender Vergleichswert  $\mathcal{G}_i$  auf Basis dieser Vorbeifahrten bestimmt. In diesem Kontext sind *ausgedehnte* Gruppen zu berücksichtigen, die potenziell an Weichen mit einer variierenden Anzahl von Vorbeifahrten für die abzweigenden Segmente auftreten können. Aus diesem Grund wird jedes die Abweichung verursachende Objekt  $\mathcal{O}_{j,i}$  einer Gruppe  $i$  einzeln betrachtet und zur Bildung des Vergleichswertes die Anzahl der Vorbeifahrten an dem Ort des Objektes  $\mathcal{V}(\mathcal{O}_{j,i})$  reziprok summiert. Dabei entspricht  $\mathcal{V}(\mathcal{O}_{j,i})$  allen Vorbeifahrten an dem Ort des Objektes im Rahmen der Messdaten, unabhängig, ob eine Abweichung aufgetreten ist oder nicht. Für den einfachsten Fall einer *punktförmigen* Gruppe auf

einem geraden Streckenabschnitt entspricht dies der Anzahl der Abweichungen bezogen auf die Anzahl der Vorbeifahrten an diesem Ort.

$$\mathcal{G}_i = \sum_{j=1}^N \frac{1}{\mathcal{V}(\mathcal{O}_{j,i})} \quad (5-2)$$

Nachfolgend links ist in Abb. 5-18 (a) die Verteilung der normierten Vergleichswerte  $\mathcal{G}$  als eCDF für alle gebildeten Gruppen dargestellt. Die Mehrheit der Gruppen weist kleine  $\mathcal{G}$  auf, was darauf hindeutet, dass sich die Abweichungen dieser Gruppen nicht systematisch mit den Vorbeifahrten wiederholen. Zur Auswahl mikroskopisch zu betrachtender Messdaten werden 30 Gruppen mit den höchsten  $\mathcal{G}$  als Hotspots ausgewählt. Dabei ist die zusätzliche Bedingung formuliert, dass nur örtliche Stellen berücksichtigt werden, an denen die Straßenbahn mindestens 10-mal vorbeigefahren ist, um statistisch nicht signifikante Ausreißer auf wenig befahrenen Strecken (bspw. selten genutztes Ausweichgleis an Endhaltestellen) zu reduzieren. In der dargestellten eCDF sind diese 30 Gruppen innerhalb des mit  $\blacklozenge$  markierten Bereichs sowie die einzelnen Vergleichswerte  $\mathcal{G}$  als Balkendiagramm nachfolgend rechts in Abb. 5-18 (b) dargestellt.

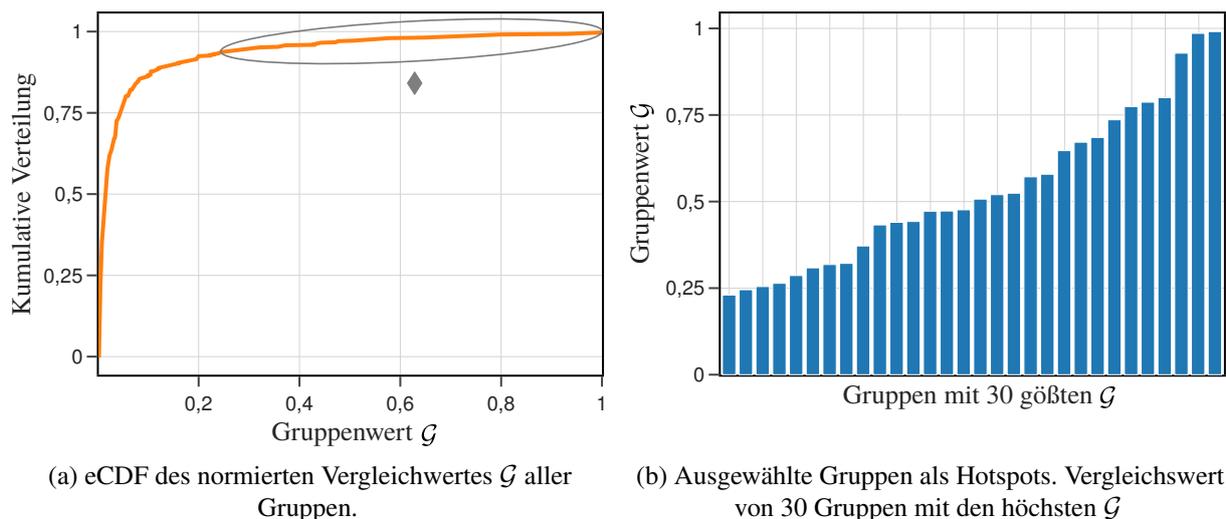


Abbildung 5-18: Normierter Gruppenvergleich basierend auf Anzahl der Abweichungen sowie der Anzahl der Vorbeifahrten.

Aus dem Balkendiagramm in Abb. 5-18 (b) geht hervor, dass der 30. Hotspot (linker Balken) nur einen Vergleichswert von  $\mathcal{G} = 0,24$  aufweist, d. h., dass es bei etwa einem Viertel aller Vorbeifahrten an diesem Ort zu Abweichungen kommt. Dem gegenüber hat der 1. Hotspot (rechter Balken) einen Vergleichswert von  $\mathcal{G} = 1,0$ , es also bei jeder Vorbeifahrt zu einer Abweichung kommt und insbesondere hier eine systematische Unzulänglichkeit der Referenzimplementierung oder Herausforderung der Automatisierung von Straßenbahnen zu erwarten ist.

Die 30 Hotspots inkludieren in Summe 2.747 Abweichungen der insgesamt 7.925  $\mathcal{A}_{\mathcal{O}}$  und repräsentieren damit rund ein Drittel der Abweichungen. Innerhalb dieser 30 Gruppen gibt es

sowohl *ausgedehnte* Hotspots mit einem maximalen Abstand von 18,8 m der Objekte innerhalb des Hotspots sowie *punktförmige* Hotspots mit einem maximalen Abstand von 0,7 m. Die exemplarische örtliche Verteilung für einen Ausschnitt des Straßenbahnnetzes ist als Kartendarstellung in Abb. 5-19 gezeigt. Die Größe der  $\bullet$  steht für den Vergleichswert  $\mathcal{G}$  des Hotspots.

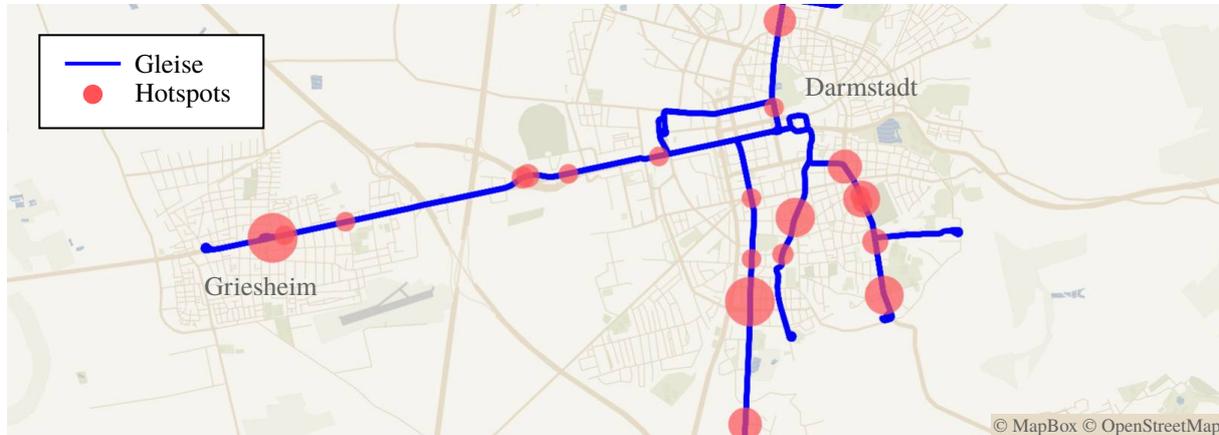


Abbildung 5-19: Kartenausschnitt des Streckennetzes mit 21 der 30  $\mathcal{A}_0^-$  Hotspots. Die Größe der  $\bullet$  indiziert den zugehörigen Vergleichswert  $\mathcal{G}$ . Eine gesamtheitliche Darstellung aller Hotspots ist in Anhang B.5.

Von den 30 gebildeten Hotspots fallen 7 nicht in unmittelbar städtisches Gebiet, sondern befinden sich auf Überlandstrecken zwischen der Kernstadt und den Stadtteilen. Dies entspricht den Erwartungen, da die im obigen Abschnitt zur makroskopischen Betrachtung des Bodens gezeigte Abb. 5-15 (b) hervorhebt, dass die meisten Abweichungen mehrheitlich auf *gepflastertem* Boden und damit im städtischen Bereich auftreten.

Für die 30 Hotspots werden zur mikroskopischen Betrachtung im nächsten Kapitel je 5 Messreihen zur stichprobenhaften Identifikation der Ursache ausgewählt. Da die Hotspots alleinig basierend auf ihrer Größe bzw. Auftreten je Vorbeifahrt erstellt sind, werden an dieser Stelle makroskopisch keine Hypothesen zu möglichen Ursachen der Hotspots formuliert.

#### 5.4.2 $\mathcal{A}_0^-$ Mikroskopische Betrachtung

Die Mehrheit aller Abweichungen  $\mathcal{A}$  tritt als  $\mathcal{A}_0^-$  auf. Zur Analyse dieser hohen Anzahl sind 12 Hypothesen formuliert sowie 30 Hotspots gebildet, die im Rahmen der mikroskopischen Betrachtung jeweils mit stellvertretenden Messreihen betrachtet werden. Für die aufgestellten Hypothesen  $\mathbf{H}_0^1$ – $\mathbf{H}_0^{12}$  werden wie in den Kapiteln zuvor die zugehörigen Nullhypothesen  $\mathbf{H}_0^0$  gebildet und diese nach Möglichkeit widerlegt.

Ebenfalls wie in den vorherigen Kapiteln wird aus Gründen der Übersicht auf die explizite Ausformulierung der Nullhypothesen verzichtet. Innerhalb dieses Kapitels werden identifizierte Effekte und Gründe vorgestellt und einzeln betrachtet bezüglich ihrer jeweiligen Bedeutung als Herausforderung der Automatisierung von Straßenbahnen eingeordnet. Die gesamtheitliche

Evaluation dieser Effekte sowie möglicher Lösungsansätze erfolgt im anschließenden Kapitel zur Teilevaluation.

In  $H_0 1$  sind Objekte mit einer Lebensdauer von 0 s als nicht real existierende Phantomobjekte mit zunächst unbekannter Ursache vermutet. Hierzu sind 40 Messreihen mit solchen Abweichungen mikroskopisch betrachtet. Mit 19 Abweichungen sind die Dachkanten von Fahrgastunterständen als häufigste gemeinsame Ursache identifiziert. Sobald die Straßenbahn auf Höhe der Dachkante ist, werden wie in Abb. 5-20 dargestellt falsch positive Reflexionspunkte in dem auf dem Dach der Straßenbahn angebrachten Velodyne VLP-32C Lidar erzeugt. Je nach Haltestelle ist die Dachkante etwa 1,3–1,4 m vom Sensor entfernt und damit eigentlich noch über der im Sensordatenblatt<sup>177</sup> angebenen unteren Grenze der Reichweite von 1,0 m. Dabei ist davon auszugehen, dass dieser Wert nicht exakt ist und es aufgrund der senkrechten Fläche, der gleichen Höhe von Fläche und Sensor sowie dem Reflexionsgrad der Dachkante (siehe Farbe der Punktwolke) zu Fehlern in der Detektion kommt.

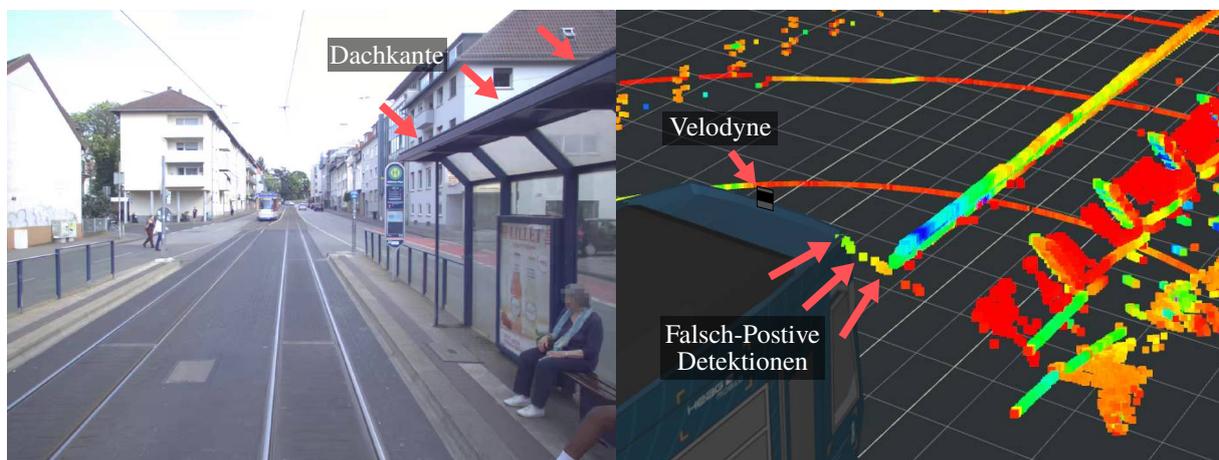


Abbildung 5-20: Velodyne VLP-32C Sensorfehler aufgrund der Nähe zur Dachkante des Fahrgastunterstandes. Die Farbskala der Lidar Punkte entspricht der Reflexionsintensität.

Von den 30 gebildeten Hotspots geht aus der mikroskopischen Betrachtung hervor, dass zwei an Haltestellen mit Fahrgastunterständen dieser Art auftreten. Dabei ist das auslösende falsch positive Objekt je nach Perspektive nur die Dachkante oder auch Teile des Fahrgastunterstandes und damit nicht eindeutig über die Objekthöhe identifizierbar. Da diese falsch positiven Objekte erst entstehen, wenn der Sensor senkrecht zur Dachkante steht und diese dann bereits in die Straßenbahn ragen, beträgt die Lebensdauer bei Eintreten der  $A_0^-$  0 s.

Der gleiche Effekt ist weiterhin in verschiedenen mikroskopischen Analysen anderer Messreihen<sup>178</sup> für den Velodyne VLP-32C an LSA sowie für den Ibeo Scala bei Hecken<sup>179</sup> in Kurvenfahrten aufgetreten. Beispielhafte Szenarien dazu sind in Anhang B.6 gezeigt. Obwohl

177 Velodyne: Datenblatt Ultra Puck VLP-32C (2017).

178 Insbesondere bei Objekten mit einer langen Lebensdauer aufgrund eines vorherigen Halts an den Haltestellen.

179 Etwa 1 m über dem spezifizierten Mindestabstand.

Fahrgastunterstand und LSA real existieren, sind die zusätzlichen Punkte des Lidars Fehldetektionen, womit  $H_{\circ}1$  zu Phantomobjekten als verifiziert gilt. Der identifizierte Effekt und damit Fehler kann in ähnlicher Weise auch bei Kraftfahrzeugen auftreten, jedoch ist die Wahrscheinlichkeit des Auftretens aufgrund der erforderlichen Nähe von Sensor und Objekt geringer. Während der Fahrt wahren Kraftfahrzeuge aufgrund der fehlenden Spurbindung für gewöhnlich einen größeren lateralen Abstand zu Objekten als die Straßenbahnen.

Insgesamt 7 der 40 betrachtenden Messreihen mit einer Objektlebensdauer von 0 s sind durch Vegetation verursacht. Durch die vertikalen Ebenen und damit Detektionslücken des Lidars, werden teilweise erst durch die Bewegung der Straßenbahn seitlich hervorstehende Pflanzenteile erfasst und dann sofort mit einer Lebensdauer von 0 s als Hindernis eingestuft. Auch sind 8 der 30 Hotspots durch Vegetation verursacht, so zeigt nachfolgende Abb. 5-21 exemplarisch die Abweichung an einem Hotspot, die durch die seitlichen Triebe eines Baums verursacht wird. Zur Verdeutlichung sind in Abb. 5-21 die Lidar Punktwolken für eine Dauer von etwa 8 s während der Vorbeifahrt in einem ortsfesten Koordinatensystem zeitlich aggregiert. Hierdurch ergibt sich für statische Objekte im Rahmen des Lokalisierungsfehlers eine höhere räumliche Auflösung der Szenerie. Sowohl in der Analyse der Abstände der Punkte wie auch in der Aggregation zeigt sich, dass die Triebe des Baums während der Vorbeifahrt an der Straßenbahn entlang schleifen.



Abbildung 5-21:  $A_{\circ}$  durch Vegetation in Form von seitlichen Trieben eines Baums. Die dargestellte Stelle entspricht einem Hotspot, bei dem es in 37 % der Vorbeifahrten zu einer Abweichung kommt. Rechts sind die Lidar Punkte für eine Dauer von etwa 8 s zeitlich aggregiert. Die Farbskala entspricht zur besseren Unterscheidung der zwei gezeigten Bäume der Ausdehnung entlang des Gleises.

Auch in allen anderen makroskopisch ausgewählten Messreihen mit Besonderheiten wie geringer Objekthöhe etc. sind unterschiedliche Formen der Vegetation einer der wesentlichen Gründe. Dabei zeigen die unterschiedlichen Szenen jedoch keine eindeutige Gemeinsamkeit bezüglich Höhe der Objekte, da wie nachfolgend exemplarisch in Abb. 5-22 gezeigt, sowohl niedrige Büsche, Gräser wie auch Bäume als Ursache identifiziert sind. Hinzu kommt, dass diese aufgrund ihrer komplexen Form und Ausdehnung (Übergang) im Lidar Clustering sowohl als einzelne Objekte wie auch als mehrere Objekte erfasst werden. In den betrachteten Abweichungen ist die kamerabasierte Klasse der Objekte erwartungsgemäß *unbekannt*.



Abbildung 5-22: Verschiedene Formen der Vegetation. Alle dargestellten Orte lösen aufgrund eines in den Fahrschlauch ragenden Objektes eine  $\mathcal{A}_O^-$  aus.

Von den 479 mikroskopisch betrachteten Messreihen sind alleine 78  $\mathcal{A}_O^-$  durch Vegetation an verschiedenen Stellen des Straßenbahnnetzes begründet. Die zugehörige Nullhypothese ist widerlegt und  $\mathbf{H}_O9$  zur Vegetation ist daher als verifiziert zu betrachten, jedoch geht der Einfluss über die Aussage der Hypothese hinaus, da nicht nur auf *offenem* und *bedecktem* Boden, sondern wie nachfolgend exemplarisch für eine Stelle in Abb. 5-23 gezeigt, in der mikroskopischen Betrachtung mehrere Orte mit Abweichungen auf *gepflastertem* Boden identifiziert sind.



Abbildung 5-23:  $\mathcal{A}_O^-$  durch Vegetation auf gepflastertem Boden. Die dargestellte Szene entspricht einem identifizierten Hotspot, wobei es in 43 % der Vorbeifahrten zu einer Abweichung kommt. Links ist in — das Polygon des getrackten Objektes  $\mathcal{O}_{\text{track}}$  gezeigt, welches in den Fahrschlauch ragt.

Die in der makroskopischen Analyse aufgestellte Hypothese  $\mathbf{H}_O2$  beschreibt als mögliche Ursache für die selten auftretenden vergleichsweise langen Lebensdauern  $> 40$  s von Objekten einiger  $\mathcal{A}_O^-$  eine fälschliche Einordnung als Hindernis nach längerer Parallelfahrt. Dazu sind 40 Messreihen mikroskopisch ausgewertet. In keiner der Messreihen ist eine fälschliche Einordnung als Hindernis nach längerer Parallelfahrt identifiziert. Vielmehr sind die  $\mathcal{A}_O^-$  mit einer langen Lebensdauer durch vorherigen Halt an Haltestelle und LSA sowie eine langsame Fahrt begründet. Da auch in anderen mikroskopisch betrachteten Messreihen keine solchen Fälle auftreten, ist die

zugehörige Nullhypothese nicht widerlegt und  $H_02$  damit nicht verifiziert. Die Mehrheit der betrachteten Messreihen von Objekten mit langer Lebensdauer ist auf Vegetation zurückzuführen.

Der zweithäufigste Auslöser dieser Stichprobe gehört zu dem nach Vergleichswert  $\mathcal{G}$  größten Hotspot bei dem es für alle aufgezeichneten Vorbeifahrten zu einer Abweichung kommt. Dieser Hotspot ist durch ein Straßennamensschild begründet, welches entsprechend dem Lidar Clustering nur etwa 4 cm in den Fahrschlauch ragt und sich auch dessen Unterkante etwa 15 cm über der Straßenbahn<sup>180</sup> befindet. Die Szenerie ist nachfolgend in Abb. 5-24 dargestellt. In der Darstellung rechts sind erneut die Lidar Punktwolke über die Zeit aggregiert, um die räumliche Auflösung der statischen Szenerie zu erhöhen.



Abbildung 5-24:  $\mathcal{A}_0$  durch Straßennamensschild. Die dargestellte Stelle entspricht mit dem Vergleichswert  $\mathcal{G} = 1,0$  dem größten Hotspot, wobei es bei allen Vorbeifahrten zu einer Abweichung kommt. In der Darstellung rechts sind die Lidar Punkte für eine Dauer von etwa 11 Sekunden während der Vorbeifahrt in einem ortsfesten Koordinatensystem zeitlich aggregiert. Die Farbskala entspricht zur besseren Unterscheidung der zwei gezeigten Bäume der Ausdehnung entlang des Gleises.

Offensichtlich handelt es sich bei dem Straßennamensschild nicht um ein reales Kollisionsobjekt, jedoch wird dieses durch die reine 2D horizontale Abstandsbetrachtung zwischen Gleis und Objektpolygon (siehe Kapitel 4.4.7) als Kritikalitätsmaß fälschlicherweise als Hindernis eingestuft. Das Schild wird durch den fließenden Übergang zusammen mit dem unteren Teil des Masts, der bis zum Boden geht, zu einem Lidar-Cluster als Objekt erfasst wird.

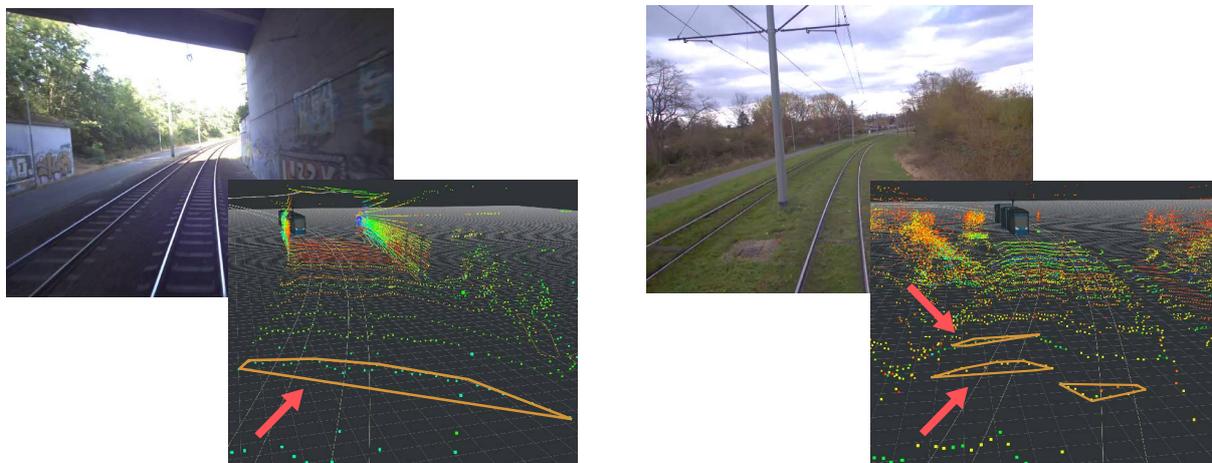
Das entstehende virtuelle Objekt hat somit keine signifikant kleine Ausdehnung in Elevation, an der es gefiltert werden könnte. Auch sind die zugehörigen Lidar Punkte mit einer Höhe von etwa 3,5 m über dem Boden noch unter der Filtergrenze welche im Rahmen der Implementierung des Lidar Clustering festgelegt worden ist. Diese ist gemäß Kapitel 4.4.3 auf 4,0 m, also der maximalen erlaubten Höhe von Kraftfahrzeugen nach der Straßenverkehrs-Ordnung (StVO) festgelegt. Neben dem oben in Abb. 5-24 dargestellten Hotspot sind weitere Stellen identifiziert, die keiner der 30 betrachteten Hotspots sind, bei denen es jedoch ebenfalls zu einer Anhäufung von Abweichungen durch Straßennamensschilder kommt.

180 Betrachtung ohne Stromabnehmer und dessen Aufbau.

Aufgrund einer signifikanten Änderung der Steigung der eCDF aller Objekthöhen bei etwa 0,6 m ist aufgrund der mehrheitlich statischen Objekte in  $\mathbf{H}_{\mathcal{O}3}$  ein Versagen des Bodenfilters als mögliche Ursache formuliert. Dazu sind 40 entsprechende Messreihen mikroskopisch betrachtet. Erneut ist mit 11 Abweichungen der häufigste Grund durch unterschiedliche Formen der Vegetation bestimmt, zumeist jedoch Gräser und Büsche. Nur in acht Fällen werden Lidar Punkte des Bodens nicht korrekt entfernt und dann als *unbekannte* Hindernisse eingestuft.

Dennoch sind von den 30 mikroskopisch betrachteten Hotspots vier durch inkorrekte Bodenfilterungen bedingt, wobei es sich hierbei um zwei Orte mit unterschiedlichen Fahrtrichtungen handelt. Die Fehler des Bodenfilters treten dabei jeweils in etwa 40–75 m Entfernung auf. Wie nachfolgend in Abb. 5-25 dargestellt, entstehen in dieser Entfernung aufgrund der endlichen vertikalen Ebenen der Lidare und verglichen mit dem Nahbereich große vertikale bzw. entlang des Bodens horizontale Detektionslücken.

Die Höhe der entstehenden Objekte sind in den mikroskopisch betrachteten Messreihen zwar mehrheitlich unter 20 cm, jedoch sind auch einzelne Szenarien identifiziert, bei denen die nicht gefilterten Bodenpunkte zusätzlich mit Masten oder umgebender Vegetation zu höheren Objekten geclustert sind. Aus diesem Grund wäre eine reine Filterung der Höhe als Maßnahmen zur Reduktion dieser Unzulänglichkeit des Bodenfilters nicht ausreichend.



(a) Höhe des Objekts etwa 16 cm aufgrund der Struktur des offenen Gleises und Gehwegs.

(b) Höhe des Objekts etwa 21 cm aufgrund der Vegetation und der Rundung des Bahndamms.

Abbildung 5-25: Die zwei Stellen der vier Hotspots, an denen das Bodenfilter besonders häufig versagt. In den 3D Darstellungen zeigt — die Polygone der detektierten Objekte  $\mathcal{O}_{\text{det}}$  an.

Diese Hotspots befinden sich jeweils für beide Fahrtrichtungen in zwei Senken bei denen die Steigungen des Gleises auf 200–300 m zwischen etwa  $-1,5^\circ$ – $2,5^\circ$  wechselt. Wie in Kapitel 4.4.3 dargestellt, wird ein Bodenfilter genutzt, welches lokale Steigungen zur Bestimmung der Bodenpunkte betrachtet. Aufgrund der geringen Punktdichte schlägt dieses Filter mit den gewählten Schwellwerten in Kombination mit den Detektionslücken sowie der Steigung des Bodens fehl.

Trotz nicht ebenem und unterschiedlichem Untergrund hat das im Rahmen der Referenzimplementierung umgesetzte Bodenfilter in den meisten mikroskopisch betrachteten Fällen korrekt funktioniert. Das Versagen an den zwei Stellen der Hotspots sowie darüber hinaus vereinzelt an anderen Stelle ist nicht als Herausforderung für die Automatisierung von Straßenbahnen zu bewerten, da durch angepasste Parameter (ggf. lokal begrenzt mittels Karte) des Filters oder den Einsatz von Lidarsensoren mit mehr vertikalen Ebenen (wie sie bereits verfügbar sind) diese falsch positiven Objekte vermieden werden können.  $H_{\mathcal{O}3}$ , welche ein Versagen des Bodenfilters als mögliche Ursache für  $\mathcal{A}_{\mathcal{O}}^-$  formuliert, gilt somit als verifiziert.

Da es sich an den betrachteten vier Hotspots in Summe jedoch nur um 126 Abweichungen handelt und diese zumeist eine Höhe unter 20 cm aufweisen, ist der Knick in der eCDF der Objekthöhen bei etwa 0,6 m damit nicht begründet. Da die Mehrheit der mikroskopisch betrachteten Objekte mit geringer Höhe sowie die Mehrheit der Hotspots auf Vegetation in Form von Büschen und Gräsern zurückzuführen ist, ist der Knick in der eCDF hierauf zurückzuführen. Für eine Verifizierung dieser Vermutung ist jedoch die Betrachtung einer größeren Stichprobe außerhalb dieser Arbeit erforderlich.

In  $H_{\mathcal{O}4}$  wird als mögliche Ursache für den signifikanten Anstieg von Objekten mit einer Höhe von 3,5–4,0 m die fälschliche Einordnung von umgebenden Bussen und Straßenbahnen als Hindernis betrachtet. Dazu sind 40 Messreihen mikroskopisch untersucht, bei denen die Objekte diesem Höhenbereich entsprechen. In 23 Fällen handelt es sich um Straßenbahnen und in drei Fällen um Gelenkbusse, die in engen 90°-Kurven der Ego-Straßenbahn entgekommen.

Aufgrund der Kurvenfahrt ändert sich einerseits maßgeblich die Perspektive der Lidarsensoren auf die entgekommenen Fahrzeuge, andererseits verändern diese aufgrund ihrer Drehgelenke ihre äußere Form. Hierdurch sehen die  $\mathcal{O}_{\text{det}}$  des Lidar Clusterings während der Kurvendurchfahrt unterschiedlich aus. Teilweise wird die Straßenbahn bzw. der Bus durch Lidar Lücken (Perspektive, ausbleibende Reflexionen aufgrund hoher Glasflächen etc.) auch als mehrere  $\mathcal{O}_{\text{det}}$  erfasst. Basierend auf der in Kapitel 4.4.5 vorgestellten Fusion werden  $\mathcal{O}_{\text{det}}$  nicht zu  $\mathcal{O}_{\text{track}}$  assoziiert, wenn sich die zugehörige Grundfläche um mehr als 50 % unterscheidet.

In den mikroskopisch betrachteten Fällen tritt dies aufgrund der signifikant unterschiedlichen Lidar-Cluster während einer Vorbeifahrt ein. Die  $\mathcal{O}_{\text{det}}$  erzeugen teilweise neue  $\mathcal{O}_{\text{track}}$ . Diese neuen  $\mathcal{O}_{\text{track}}$  sind jedoch nicht die  $\mathcal{A}_{\mathcal{O}}^-$  auslösenden Objekte. Die älteren  $\mathcal{O}_{\text{track}}$  aus vorherigen Detektionen werden wie in Kapitel 4.4.5 vorgestellt bis 500 ms basierend auf ihrer zuletzt bekannten Position mit einer als konstant angenommenen Geschwindigkeit geschätzt. Durch die Modellierung mittels konstantem Geschwindigkeitsmodell bewegt sich das geschätzte Objekt tangential aus der Kurve heraus und ragt damit in den Fahrschlauch der Ego-Straßenbahn. Ein Beispielszenario dazu ist nachfolgend in Abb. 5-26 dargestellt. Die Position eines zuvor erstellten  $\mathcal{O}_{\text{track}}$  einer mit etwa 15 km/h entgekommenen Straßenbahn wird innerhalb von 200 ms um 83 cm falsch geschätzt. Das zugehörige Polygon ragt hierdurch etwa 47 cm in den Fahrschlauch der Ego-Straßenbahn und löst eine  $\mathcal{A}_{\mathcal{O}}^-$  aus.

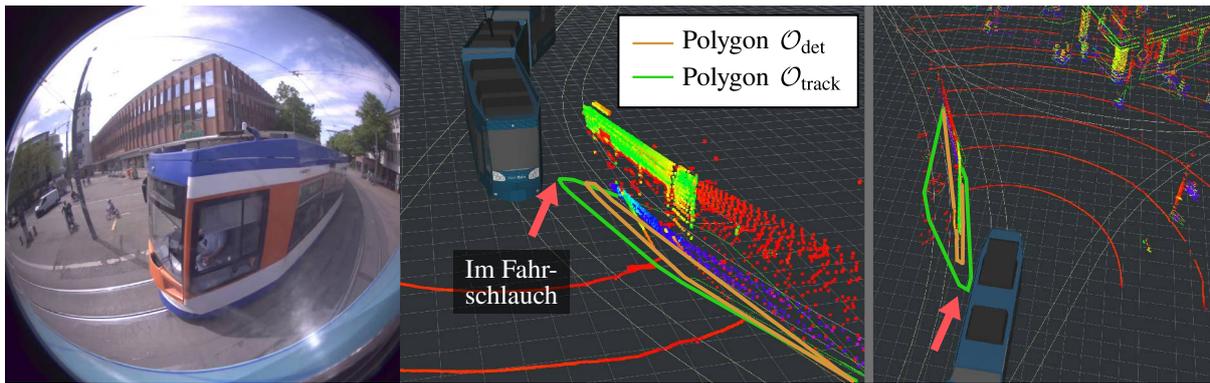


Abbildung 5-26: Beispielszenario für  $\mathcal{A}_{\bar{O}}$  durch Versagen der Zustandsschätzung. Durch Perspektivwechsel und Verformung der Bahn wird die Straßenbahn in der Kurve vom Lidar Clustering unterschiedlich erfasst. Diese  $\mathcal{O}_{\text{det}}$  werden aufgrund des unterschiedlichen Aussehens nicht zu bestehenden  $\mathcal{O}_{\text{track}}$  (also vorherigen Lidar Clustern) assoziiert. Die Bewegung alter, nicht mehr durch Messungen aktualisierter  $\mathcal{O}_{\text{track}}$  wird aufgrund des genutzten Bewegungsmodells in Kurvenfahrten falsch prädiziert.

Die zugehörige Nullhypothese ist somit widerlegt und Hypothese  $\mathbf{H}_{\bar{O}4}$  gilt als verifiziert. Auslöser dieser  $\mathcal{A}_{\bar{O}}$  ist die Kombination von erschwerter Objektdetektion aufgrund des veränderten Aussehens aus Sensor Perspektive, der Assoziation von  $\mathcal{O}_{\text{det}}$  und  $\mathcal{O}_{\text{track}}$  sowie der Modellierung der  $\mathcal{O}_{\text{track}}$  mit konstanter Geschwindigkeit und dem stellenweise geringen Abstand von Fahrzeugen des ÖPNV zueinander.

Auch wenn die Nähe der Fahrzeuge zueinander als Herausforderung der Automatisierung von Straßenbahnen bzw. des ÖPNV im Allgemeinen einzuordnen ist, so sind insbesondere die restlichen Unzulänglichkeiten allgemeine Herausforderungen der Automatisierung von Fahrzeugen und durch Anpassungen der Referenzimplementierung mit komplexeren Methoden lösbar. Insbesondere bietet sich die Möglichkeit, dass entgegenkommende Straßenbahnen ebenfalls spurgebunden sind und somit eine Kollision außerhalb von Bereichen mit Begegnungsverbot ausgeschlossen ist.

Obwohl die Lidar Punkte auf 4,0 m über Schienenhöhe mittels Filter begrenzt sind, zeigt die im vorherigen Kapitel dargestellte eCDF der Objekthöhen einige wenige Objekte mit einer Höhe über 5,0 m. Daher wird in  $\mathbf{H}_{\bar{O}5}$  ein fehlerhaftes Clustering mehrerer Objekte mit außerhalb des Gleises tiefer liegenden Objekten als mögliche Ursache formuliert. Dazu sind 28 Messreihen und somit alle  $\mathcal{A}_{\bar{O}}$  des Datensatzes mit einer Objekthöhe über 5,0 m mikroskopisch ausgewertet. 15 dieser Ereignisse sind nicht durch reale, tiefliegende Objekte verursacht, sondern durch Falsch-Positive wie der zuvor beschriebene Prädiktionsfehler, Blooming (Erläuterung folgt ab Seite 132) oder Vegetation. Dabei weisen die Objekte eine Höhe über 5,0 m auf, da fehlerhafte Lidardetektionen unter den realen Objekten in Folge von Mehrfachreflexionen entstehen.

In allen 15 Fällen sind die Mehrfachreflexionen durch einen feuchten Untergrund während oder nach Regen bedingt. Beispielhaft ist nachfolgend in Abb. 5-27 ein Szenario gezeigt, bei dem im Frontbereich unterhalb der entgegenkommenden Straßenbahn Mehrfachreflexionen zu

inkorrekten Detektionen des Lidars führen. Die  $\mathcal{A}_O^-$  wird wie in obiger Abb. 5-26 beschrieben durch ein ungenügendes Tracking und eine falsche Prädiktion verursacht.

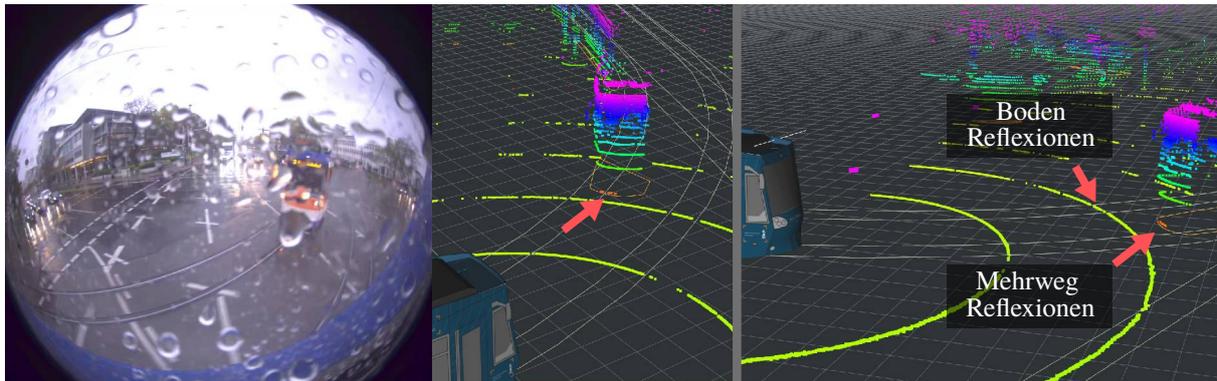


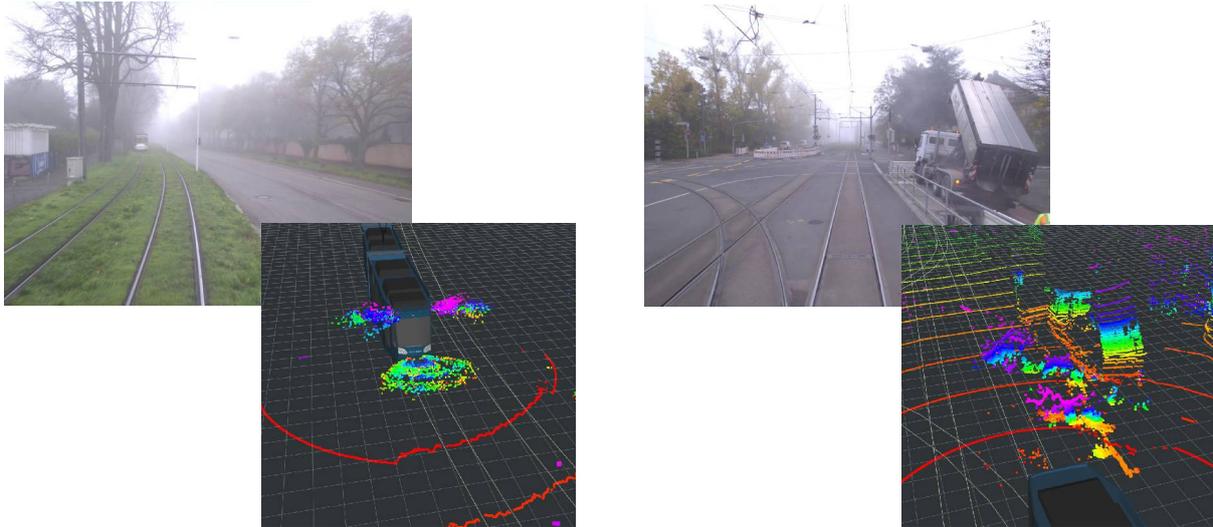
Abbildung 5-27: Lidar Mehrwegreflexionen am nassen Boden. Die Farbskala entspricht der Höhe. Die Mehrfachreflexionen sind als tiefste Punkte in rot dargestellt, während die darüber liegenden Punkte des Bodens gelb-grün sind.

Dieser Effekt ist für Lidar bekannt.<sup>181</sup> Da die Mehrfachreflexionen nicht die Auslöser der  $\mathcal{A}_O^-$  sind, handelt es sich hierbei nicht um eine spezifische Herausforderung bei der Automatisierung von Straßenbahnen, sondern einer allgemeinen Unzulänglichkeit von Lidar. Die restlichen, nicht durch Mehrfachreflexionen bedingten,  $\mathcal{A}_O^-$  mit einer Objekthöhe über 5,0 m werden durch Vegetation verursacht, die aufgrund von Böschungen, Brücken und Bahndämmen tiefer beginnen als die Schienenoberkante. Da in  $\mathbf{H}_O5$  die Zusammenfassung mehrerer Objekte als mögliche Ursache formuliert ist, ist die zugehörige Nullhypothese nicht widerlegt und  $\mathbf{H}_O5$  nicht verifiziert.

Aufgrund *unbekannter* stehender Hindernisse an Bahnübergängen ist zuvor in  $\mathbf{H}_O6$  ein Versagen des Bodenfilters für Lidar Punkte als mögliche Ursache beschrieben. Dazu sind 20 Messreihen mikroskopisch ausgewertet. In keinem der Fälle handelt es sich um ein Versagen des Bodenfilters. Alle Abweichungen sind ausschließlich begründet durch falsch positive Objekte aufgrund von Vegetation, Blooming (wird im späteren Verlauf erläutert) sowie zu nahe LSA, die im Velodyne VLP-32C wie zu Beginn des Kapitels für Fahrgastunterstände beschrieben, zu Fehldetektion führen. Auch wenn es wie oben aufgezeigt  $\mathcal{A}_O^-$  für einzelne örtliche Stellen gibt, die durch ein Versagen des Bodenfilters begründet sind, so sind keine mikroskopische Auffälligkeit hierzu an Bahnübergängen identifiziert. Die Hypothese  $\mathbf{H}_O6$  welches dies als mögliche Ursache beschreibt, ist damit nicht verifiziert.

Da einige wenige  $\mathcal{A}_O^-$  unabhängig der Lebensdauer der Objekte lang andauern und die längste Abweichung 65 s beträgt, sind in  $\mathbf{H}_O7$  Sensorfehler als möglicher Ursache formuliert. Aus allen  $\mathcal{A}_O^-$  ergeben sich 25 Messreihen bei denen die Abweichung mehr als 30 s andauert und damit stellvertretend mikroskopisch betrachtet werden. In allen Fällen handelt es sich um falsch positive Objekte aufgrund von Nebel und vereinzelt Schnee. Dabei entstehen in beiden Lidarsensoren wie nachfolgend in Abb. 5-28 für zwei Beispielszenen gezeigt fehlerhafte Detektionen.

181 Hasirlioglu, S.; Riener, A.: Simulating Rain Effects on Sensor Data (2020), S. 431.



(a) Nebel löst im Nahbereich vor den Sensoren sowohl im Velodyne VLP-32C wie auch im Ibeo Scala falsch positive Objekte aus.

(b) Witterungsbedingter Nebel sowie zusätzlicher (kaum sichtbarer) Dampf durch Asphaltarbeiten.

Abbildung 5-28:  $\mathcal{A}_{\bar{O}}$  mit langer Dauer aufgrund von Nebel. Die Farbskala entspricht den vertikalen Ebenen des Lidar.

Obige Abb. 5-28 (a) links zeigt fehlerhafte Detektionen im unmittelbaren Bereich vor den Sensoren. Sowohl für das dargestellte Beispielszenario wie auch andere Messreihen zeigt sich, dass der Velodyne VLP-32C Lidar im Nahbereich selten Fehldetektion im horizontalen FoV des Ibeo Scala aufweist. Weitere Beispiele dazu sind in Anhang B.7 gezeigt. Eine mögliche Erklärung ist der sogenannte Cross-Talk zwischen den Sensoren und damit höhere dynamische Schwellwerte in der Auswertung. Dies ist jedoch nur eine Vermutung, weshalb hierzu weitere Untersuchungen außerhalb dieser Arbeit erforderlich sind. Darüber hinaus kommt es auch zu weiter entfernten falsch positiven Punkten, die wie in Anhang B.7 gezeigt auch konzentrierte Anhäufungen ähnlich einem real existierenden Objekt entsprechen. Neben reinem witterungsbedingtem Nebel ist oben rechts in Abb. 5-28 (b) ein Szenario dargestellt, bei dem neben Nebel zusätzlich Dämpfe durch Asphaltarbeiten entstehen. Der gezeigte Lkw schüttet Asphalt ab, von dem zusätzlich in geringem Maße Dampf ausgeht und über die Gleise zieht. Aufgrund der hohen Empfindlichkeit des Sensors durch den witterungsbedingten Nebel reicht dieser zusätzliche Wasserdampf aus, um Fehldetektionen vor der Straßenbahn zu verursachen. Als ähnliche Ursache und Effekt sind vereinzelt  $\mathcal{A}_{\bar{O}}$  bedingt durch Abgase von Kraftfahrzeugen an kalten bzw. regnerischen Tagen identifiziert.

Die degradierte Sichtweite durch Nebel ist für Lidar bekannt<sup>182, 183</sup> und eine allgemeine noch zu lösende Herausforderung für die Automatisierung aller Fahrzeuge und nicht spezifisch für Straßenbahnen. Die Hypothese  $\mathbf{H}_{\bar{O}7}$  welche aufgrund von Nebel hervorgerufener Sensorfehler als Ursache beschreibt, ist somit verifiziert.

182 Kutilla, M. et al.: Automotive LiDAR performance verification in fog and rain (2018).

183 Li, Y. et al.: What Happens for a ToF LiDAR in Fog? (2021).

Aufgrund einer Vielzahl  $\mathcal{A}_O$  die durch stehende Objekte auf *offenem* und *bedecktem* Untergrund ausgelöst werden, ist in Hypothese **H<sub>O</sub>8** die unmittelbare Infrastruktur als mögliche Ursache formuliert. Im Rahmen der mikroskopischen Betrachtung ist sogenanntes Lidar Blooming an Verkehrsschildern in 13 der 30 gebildeten Hotspots sowie für eine Vielzahl weiterer in diesem Kapitel betrachteter Messreihen als Ursache identifiziert. Beispiele hierzu sind nachfolgend in Abb. 5-29 gezeigt. Der Blooming oder auch Bleeding genannte Effekt ist für Lidar ein bekanntes Problem,<sup>184, 185</sup> bei dem zusätzliche inkorrekte Punkte neben einer stark reflektierenden Oberfläche entstehen. Aufgrund der Retroreflektivität von Verkehrsschildern<sup>186</sup> kommt es durch die ungewünschte Aufweitung der entsendeten Lidarstrahlen zu ausreichend hohen Reflexionen, die zu Detektionen außerhalb des eigentlichen Winkelerfassungsbereichs des jeweiligen Lidarstrahls führen. Hinzu kommt in vertikaler Richtung, dass es ebenfalls aufgrund der Retroreflektivität zu einem Überstrahlen der Lidarebenen untereinander kommen kann. Somit werden wie nachfolgend für verschiedene Szenarien in Abb. 5-29 beispielhaft gezeigt, um Verkehrsschilder fehlerhafte Lidar Detektion erzeugt, an deren eigentlicher Position sich nichts befindet. Die fehlerhaften Detektionen werden mit dem Verkehrsschild zusammen zu einem Objekt geclustert, welches aufgrund der fälschlichen lateralen Ausdehnung in den Fahrschlauch der Straßenbahn ragt und Bremsung im OuT auslöst.

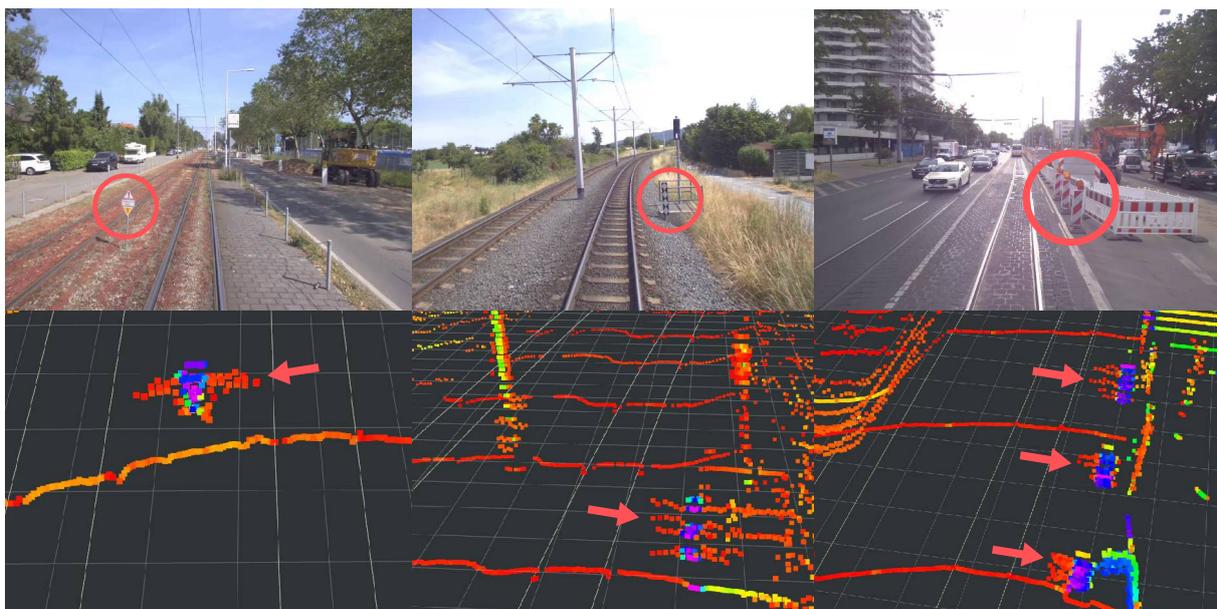


Abbildung 5-29: Lidar Blooming an Verkehrsschildern. Oben Referenzbilder der Szenerie, unten die Lidar Punktvolke von Velodyne VLP-32C sowie Ibeo Scala. Die Farbe der Punkte entspricht der Reflexionsintensität. Die roten Punkte (niedrige Intensität) neben dem blau-lila retroreflektierendem Verkehrsschild (hohe Intensität) sind fehlerhafte Detektionen, die in den Fahrschlauch ragen. Alle drei gezeigten Szenarien sind Hotspots.

Anhand der mikroskopischen Betrachtung zeigt sich kein wesentlicher Unterschied bezüglich der

184 Vosselman, G.; Maas, H. G.: Airborne and terrestrial laser scanning (2010), S. 99.

185 Lambert, J. et al.: Performance Analysis of LiDARs (2020), S. 131705.

186 Verkehrsschilder sind üblicherweise mit einer retroreflektierenden Folie beklebt, um Nachts Licht vom Scheinwerfer zurück zum Pkw zu werfen und so eine bessere Lesbarkeit des Schildes zu ermöglichen.

zwei eingesetzten Lidarsensoren. Dieser Effekt tritt gleichermaßen für den Velodyne VLP-32C wie auch den Ibeo Scala auf. Aufgrund der FoV der Sensoren fallen jedoch insbesondere im Nahbereich mehr Strahlen des Ibeo Scala auf die mehrheitlich niedrigeren Verkehrsschilder (wie in obiger Abbildung) und erzeugen dabei fehlerhafte Detektionen. In 10 der 13 Hotspots, die durch Blooming verursacht sind, handelt es sich um Verkehrsschilder der Straßenbahn auf besonderem oder unabhängigem Bahnkörper, wie es oben links und mittig in Abb. 5-29 gezeigt ist. Aufgrund der Spurbindung der Straßenbahn und dem nicht anderweitig geteilten Verkehrsraum sind an diesen Stellen Verkehrsschilder meist näher an der Straßenbahn als dies auf einem straßenbündigen Bahnkörper bzw. mit anderen Teilnehmern geteiltem Verkehrsraum der Fall ist.

Bei nur einem Hotspot kommt es bei jeder Vorbeifahrt zu einer  $\mathcal{A}_O^-$ . Bei den anderen treten zwar mehrheitlich Abweichungen auf, jedoch hat die mikroskopische Auswertung von Vorbeifahrten ohne Abweichung gezeigt, dass Blooming auch teilweise nicht oder reduziert auftritt. Insbesondere auffällig im Rahmen der mikroskopischen Betrachtung ist jedoch ein verstärktes Auftreten sowie signifikant ausgeprägteres Blooming bei Regen. Nachfolgend ist in Abb. 5-30 beispielhaft die Annäherung an einen Mast mit mehreren Verkehrsschildern bei Regen gezeigt. Eine Überprüfung der Literatur zu Wettereffekten auf Lidar hat keine Hinweise auf eine mögliche Erklärung des verstärkten Bloomings gezeigt. Mögliche Ursachen könnten eine erhöhte Empfangsleistung aufgrund von Mehrwegreflexionen oder eine Anpassung in der Identifikation von Reflexionsmaxima der internen Sensorauswertung aufgrund des Regens sein. Zur eindeutigen Klärung sind weitere Untersuchungen außerhalb dieser Arbeit erforderlich.

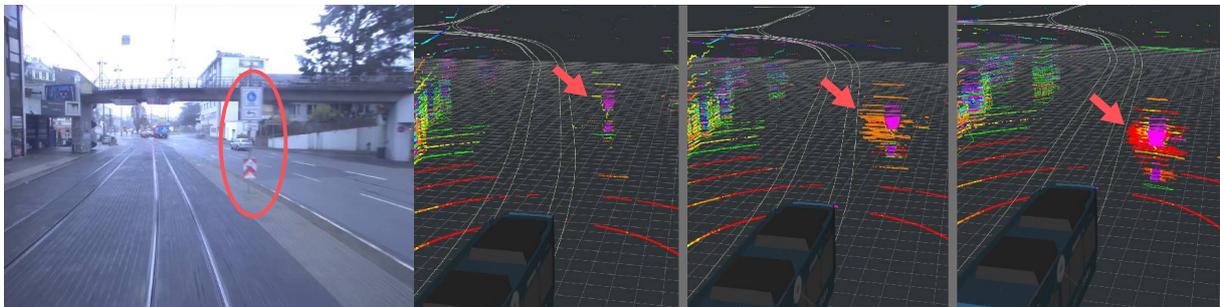


Abbildung 5-30: Beispiel für Lidar Blooming bei Nässe. Die Farbe der Punkte entspricht der Reflexionsintensität. Die Lidar Darstellungen zeigen die Annäherung an den im Bild gezeigten Verkehrsmasten. Je näher der Sensor der retroreflektierenden Oberfläche kommt, desto mehr Punkte werden durch Blooming erzeugt.

Die 13 der 30 gebildeten Hotspots umfassen in Summe 1100  $\mathcal{A}_O^-$ . Aufgrund des Effektes und der Häufigkeit von Verkehrsschildern, die sich nah am Fahrschlauch befinden, ist davon auszugehen, dass eine Vielzahl weiterer Abweichungen durch Blooming verursacht werden. Die Hypothese  $\mathbf{H}_{O8}$  ist damit verifiziert. Es wurde jedoch keine mikroskopische Messung identifiziert, welche auf eine unzureichende Auflösung oder Genauigkeit von Lidarsensoren sowie dem kartenbasierten Abruf des Fahrschlauches in Kombination der Lokalisierung schließen lässt. Abweichungen der Infrastruktur sind — neben dem oben aufgezeigten Versagen des

Bodenfilters sowie aufgrund von oberhalb der Straßenbahn befindliche Straßennamensschilder — insbesondere durch Blooming verursacht.

Zwar ist Blooming ebenfalls eine Herausforderung für die Automatisierung von Kraftfahrzeugen und kann dort bspw. an Gebotsschildern zu Verkehrsinseln oder Baustellenbarken ebenfalls zu fehlerhaften Detektionen in der Nähe des Fahrschlauches führen, jedoch kann die Straßenbahn im Gegensatz zu Kraftfahrzeugen diesen durch Blooming verursachten Punkten nicht durch eine Anpassung der Trajektorie (innerhalb des eigenen Fahrstreifens) ausweichen. Hinzu kommt die Häufigkeit solcher Verkehrsschilder, die aufgrund der Spurbindung der Straßenbahn vor allem auf besonderem und unabhängigem Bahnkörper mutmaßlich häufiger in der Nähe des Fahrschlauches sind, als dies im öffentlichen Straßenverkehr für Kraftfahrzeuge der Fall ist.

In Kapitel 4.4.7 ist aufgezeigt, dass das OuT im Rahmen der umgesetzten Verhaltensplanung schätzt, ob Hindernisse den Fahrschlauch verlassen werden, bevor die Auslösung einer starken Verzögerung erforderlich wäre. Dazu wird anhand der Geschwindigkeit des Objektes die Zeit zum Verlassen des Fahrschlauches mit der verbleibenden Zeit bis zu einer Kollision bzw. dem erforderlichen Auslösen einer starken Bremsung verglichen. Basierend auf denen nicht als *unbekannt*, sondern als Verkehrsteilnehmer (Pkw, Fußgänger etc.) klassifizierten Objekten, die eine Abweichung auf *gepflastertem* Untergrund verursachen, ist in  $\mathbf{H}_0\mathbf{10}$  eine ungenügende Intentionserkennung als mögliche Ursache formuliert. Dazu sind zusätzlich 40 Messreihen mit klassifizierten Objekten auf *gepflastertem* Untergrund mikroskopisch ausgewertet. Die größte Gruppe mit gemeinsamer Ursache bilden 17  $\mathcal{A}_0$ , die sich auf Sensorfehler in Form von Blooming oder Dachkanten von Fahrgastunterständen (s.o.) zurückführen. Aufgrund unmittelbar dahinter befindlicher Pkw oder davor befindlicher Personen sind diese fälschlich als solche klassifiziert. Beispiele für die jeweiligen Szenarien sind in Abb. 5-31 gezeigt.

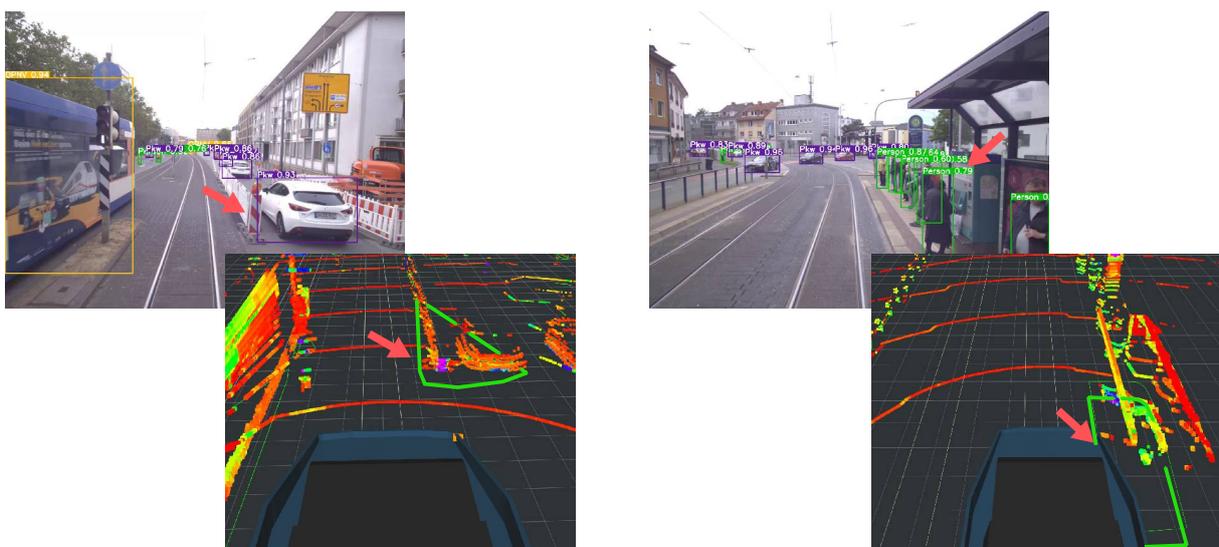


Abbildung 5-31: Beispiele für Fehlklassifikation und Fehlclustering von Objekten. Links verursacht Blooming ein fälschlich als Pkw klassifiziertes Objekt. Rechts wird Fahrgastunterstand mit den Personen zu einem Objekt zusammengefasst und aufgrund von Fehldetektionen an der Dachkante eine  $\mathcal{A}_0$  verursacht.

Die Klassenzuweisung in obiger Abb. 5-31 versagt einerseits durch die überlagerte Projektion der 3D-Objekte ins 2D-Kamerabild, andererseits aufgrund einer fehlenden Trennfähigkeit im Lidar Clustering. Sowohl die unten gezeigte Baustellenbarke, wie auch die Dachkante des Fahrgastunterstandes werden im Lidar-Clustering mit dem Pkw bzw. den Personen zu einem Objekt zusammengefasst.

Neben der oben aufgezeigten Trennfähigkeit zu Elementen der Infrastruktur sind vereinzelt auch Szenarien identifiziert, bei denen mehrere dynamische Objekte fälschlich zu einem virtuellen Objekt zusammengefasst werden und eine  $\mathcal{A}_{\mathcal{O}}^-$  verursachen. Der auslösende Grund ist dabei nicht die grundsätzliche Belegung innerhalb des Fahrschlauches, wie es für die obigen Fälle der Infrastruktur gilt, sondern eine fehlerhafte Zuweisung der Objektgeschwindigkeit. So zeigt nachfolgende Abb. 5-32 die Folgefahrt hinter Fußgängern und Radfahrern während eines Festes in der Innenstadt. Da sowohl menschlicher Fahrer wie auch OuT den Hindernissen gleichermaßen folgen, kommt es zunächst zu keiner Abweichung. Die in der Vergrößerung markierte Person nähert sich entsprechend der Lidar Punktwolke jedoch der entgegenkommenden Straßenbahn auf bis zu unter 30 cm und wird durch das Lidar-Clustering mit dieser Straßenbahn zu einem virtuellen Objekt zusammengefasst. Das entstehende Objekt aus Straßenbahn und Person ragt, wie die Person zuvor als einzelnes  $\mathcal{O}_{\text{det}}$  auch, weiterhin in den Fahrschlauch. Im Gegensatz zu vorherigen Zeitschritten weist das in den Fahrschlauch ragende Objekt nun die Geschwindigkeit der entgegenkommenden Straßenbahn auf. Das OuT reagiert daher aufgrund des entgegenkommenden Objektes im eigenen Fahrschlauch mit einer stärkeren Verzögerung entsprechend der beschriebenen Verhaltensplanung.

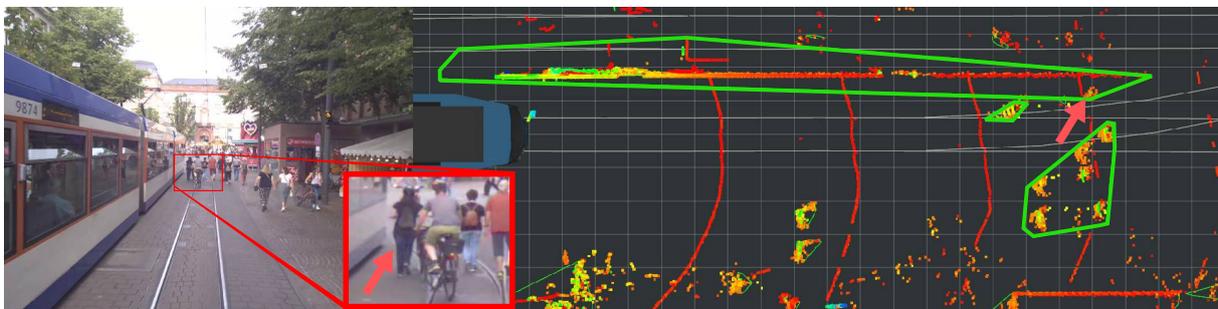


Abbildung 5-32: Beispiel für fehlende Trennfähigkeit des Lidar Clusterings. Die markierte Person wird mit der entgegenkommenden Straßenbahn zusammengeclustert. Das entstehende Objekt ragt in den Fahrschlauch und löst aufgrund des entgegenkommenden Geschwindigkeitsvektors eine Bremsung aus. Ebenfalls zu erkennen ist die fehlende Trennung der weiter entfernten Menschengruppe.

Die fehlende Trennfähigkeit des Lidar Clustering ist wesentlich durch zwei Einflüsse bedingt. Einerseits bewirken vertikale Detektionslücken des Lidars sowie die physikalisch bedingte winkelbasierte horizontale Auflösung eine abnehmende Punktdichte für Objekte mit größeren Entfernungen. Die Trennfähigkeit in Abhängigkeit der reduzierten Punktdichte ist durch die Kapitel 4.4.3 beschriebenen Funktionsweise und Parameter der gewählten Cluster-Bildung bestimmt. Andererseits können Personen, die sich an Infrastruktur wie bspw. an einen Fahrgastunterstand anlehnen oder darin sitzen, auch bei einer höheren räumlichen Auflösung des Lidars

mit den vorhandenen analytischen Clustermethoden aufgrund des kontinuierlichen Übergangs nicht als einzelne Objekte getrennt werden. Da sich diese anlehenden oder sitzenden Personen jedoch nicht bewegen und so auch kein Hindernis darstellen, ist dies für die Verhaltensplanung unproblematisch. Sobald sich diese Personen, wie nachfolgend für Objekte mit unbekannter Geschwindigkeit aufgezeigt, jedoch bewegen, sind sie einzeln zu detektieren, um ihre Intention für ein korrektes Ego-Verhalten abschätzen zu können. Dies ist wiederum für Sensoren wie Radar oder neuartige FMCW Lidare (werden nachfolgend erläutert), erleichtert, da die Trennfähigkeit dieser Sensoren bzw. nachgelagerter Auswertemethoden durch die zusätzliche Nutzung des Dopplereffektes und der daraus bestimmten Geschwindigkeit von Detektionen verbessert ist. Es ist daher an dieser Stelle auch zu erwähnen, dass für das oben gezeigte Beispiel auch eine *Low-Level-Fusion* anstelle der genutzten *High-Level-Fusion* (siehe Kapitel 4.4.5) der Lidar- und Radardetektionen eine Verbesserung der Trennfähigkeit ermöglichen würde. Zwar weisen Kraftfahrzeuge die Problematik der Trennfähigkeit grundsätzlich ebenfalls auf, jedoch ist diese Herausforderung für den ÖPNV mit seinem Einsatz in der Innenstadt und Haltestellen ausgeprägter.

Weiterhin sind in den 40 Messreihen mit klassifizierten Objekten auf *gepflastertem* Untergrund sowie in verschiedenen anderen in diesem Kapitel betrachteten Schwerpunkte mehrere  $\mathcal{A}_O^-$  aufgetreten, bei denen das OuT kreuzende oder sich im Fahrschlauch befindliche Verkehrsteilnehmer fälschlich als Hindernis einordnet. Als Ursache sind dabei zwei Effekte identifiziert:

**Geschwindigkeit unbekannt:** In den betrachteten Messreihen weisen insbesondere kreuzende Fußgänger häufig eine unbekannte Geschwindigkeit auf. Mit der umgesetzten Verhaltensplanung wird aufgrund der fehlenden Geschwindigkeit kein kreuzendes Verhalten erkannt und das OuT beginnt für ein fälschlich als stehend angenommenes Hindernis im Fahrschlauch zu bremsen. Im Rahmen der hier vorgestellten Referenzimplementierung wird die Geschwindigkeit der Objekte als Teil der Fusion alleinig durch den Radarsensor bestimmt. Dieser wiederum misst die relative Geschwindigkeit in radialer Richtung (vom Sensor) basierend auf dem Dopplereffekt.<sup>187</sup> In Richtung der Winkelkoordinate (orthogonal zur radialen Richtung) ist eine Bestimmung der Geschwindigkeit mittels Dopplereffekt jedoch physikalisch nicht möglich. Kreuzende Fußgänger bewegen sich jedoch quasi tangential zum Radar und damit in Richtung der Winkelkoordinate. Die Radare schätzen für bestehende Objekte auf einem internen Tracking, unter anderem diesen Anteil der Geschwindigkeit, basierend auf anderen Indikatoren wie der Veränderung der Position. Einerseits ist eine solche Schätzung fehleranfällig, andererseits kommt es dazu, dass kreuzende Fußgänger vom Radar erst gar nicht als Objekt detektiert werden. Eine mögliche Ursache hierfür ist die erschwerte Objektbildung aufgrund des Fehlens des Dopplereffektes, während dem quasi tangentialen Kreuzen der Fußgänger und damit eine reduzierte Trennfähigkeit der empfangenen Detektionen. In den Messreihen ist das Ausbleiben eines Objektes be-

187 Winner, H. et al.: Handbuch Fahrerassistenzsysteme (2015), S. 263 ff.

sonders häufig an für den Radar stark reflektierenden Fahrgastunterständen aufgetreten, wie es nachfolgend in Abb. 5-33 gezeigt ist. Die Fußgänger werden durch die beiden Lidare korrekt als Objekt geclustert, jedoch der Verhaltensplanung ohne Geschwindigkeit übergeben.



Abbildung 5-33: Beispiel I Versagen der Kreuzungsvorhersage aufgrund fehlender Geschwindigkeit. Die kreuzenden Fußgänger werden durch das Lidar-Clustering korrekt erfasst jedoch gibt der Radar kein Objekt aus, womit die Geschwindigkeit nicht bekannt ist und das OuT für ein vermeintlich stehendes Objekt zu bremsen beginnt.

Neben den oben gezeigten Objekten in Fahrgastunterständen sind in der mikroskopischen Betrachtung insbesondere im Bereich von Fußgängerzonen mehrere  $\mathcal{A}_O^-$  identifiziert, bei denen sich einzelne Personen aus Menschenmengen lösen und die Gleise überqueren, wie es beispielhaft nachfolgend in Abb. 5-34 gezeigt ist. Aufgrund der quasi tangentialen Bewegung zum Radar ist die Geschwindigkeit der Fußgänger nicht bekannt und das OuT beginnt für ein vermeintlich stehendes Objekt zu bremsen. In dem gezeigten Innenstadtszenario ist die Person im letzten Bild etwa 6 m entfernt, während die Straßenbahn mit etwa 13 km/h auf sie zu fährt. Aufgrund des stehenden Objektes und der in Kapitel 4.4.7 aufgezeigten Halteregelung wird zusätzlich ein Halteabstand von  $d_{\text{halt}} = 3,0$  m berücksichtigt und so eine Sollverzögerung von  $a_{\text{OuT}} \approx -2,1$  m/s<sup>2</sup> geplant. Der menschliche Fahrer lässt die Straßenbahn zeitgleich mit  $a_{\text{ego}} \approx 0$  m/s<sup>2</sup> rollen und es kommt aufgrund  $\Delta a > a_{\text{krit}}$  zur Abweichung.



Abbildung 5-34: Beispiel II Versagen der Kreuzungsvorhersage aufgrund fehlender Geschwindigkeit. Die kreuzenden Fußgänger werden durch das Lidar-Clustering korrekt erfasst jedoch gibt der Radar kein Objekt aus, womit die Geschwindigkeit nicht bekannt ist und das OuT für ein vermeintlich stehendes Objekt zu bremsen beginnt.

**Geschwindigkeit nicht ausreichend:** Weiterhin ergibt die mikroskopische Betrachtung, dass auch im Kontext der eigentlich vorfahrtsberechtigten Straßenbahn eine Erkennung der Intentionen eines Objektes nicht ausreichend mit der Geschwindigkeit dieses Objektes bestimmt werden kann. In der gesamtheitlichen Betrachtung aller in diesem Kapitel ausgewerteter Messreihen sind mehrere komplexe Szenarien identifiziert, bei denen andere Verkehrsteilnehmer während des Kreuzens auf den Gleisen stehen bleiben, da sie selbst anderweitig warten müssen oder durch Fahrt auf den Gleisen diesen Verkehrsraum belegen. Beispielhaft dazu ist nachfolgend in Abb. 5-35 das Entgegenkommen und Abbiegen eines Pkw gezeigt, der bis kurz vor dem eigentlichen Abbiegen mit etwa 60 cm Überlappung im Fahrschlauch der Straßenbahn fährt. In dem mittleren Bild haben Straßenbahn und Pkw eine Relativgeschwindigkeit von 47 km/h bei 13 m Abstand. Aufgrund der noch nicht aufgebauten Geschwindigkeit zum Abbiegen schätzt das OuT den Pkw als Hindernis ein und beginnt zu bremsen. Der menschliche Fahrer der Straßenbahn antizipiert das Abbiegen — mutmaßlich anhand des Fahrrichtungsanzeigers des Pkw — und lässt die Straßenbahn unbeschleunigt mit 17 km/h rollen.

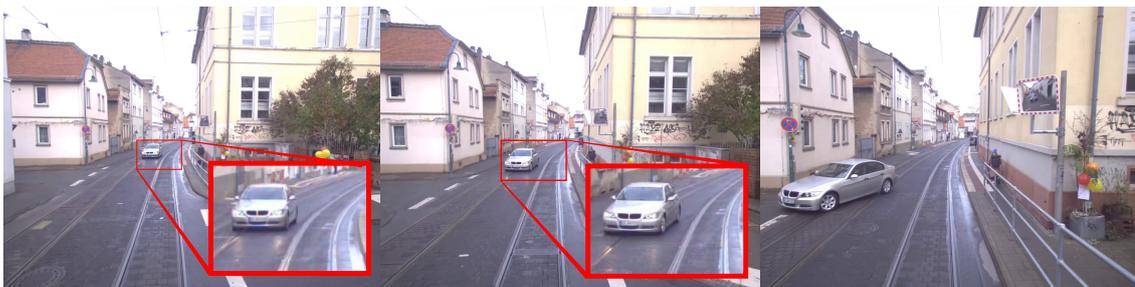


Abbildung 5-35: Beispiel I für Versagen aufgrund fehlender Intentionserkennung. Die Geschwindigkeit des Pkw ist detektiert, reicht jedoch nicht aus, um die Intention des Abbiegens zu erkennen.

Neben Szenarien im öffentlichen Verkehrsraum sind ebenfalls mikroskopisch mehrere  $\mathcal{A}_O$  identifiziert, bei denen Fußgänger auf besonderen Bahnkörpern oder im Bereich der Innenstadt an Engstellen bedingt durch Mauern, Zäune, Gebäude etc. sehr dicht am Gleis stehen oder laufen und für einen kurzen Zeitraum in den Fahrschlauch ragen, weil sie entweder auf die Gleise treten oder auch nur Taschen oder Arme in den Fahrschlauch ragen lassen. Ohne weitere Untersuchungen scheint es mutmaßlich, dass der Fahrer prüft, ob der Fußgänger die Bahn wahrgenommen hat und antizipiert, ob der Fußgänger bis zum Eintreffen der Bahn nicht mehr im Fahrschlauch sein wird. Als Beispiel ist dazu nachfolgend in Abb. 5-36 der Aufenthalt einer Familie mit Kinderwagen zwischen Bauzaun und Gleisen gezeigt. Anhand der Blickrichtung<sup>188</sup> in der Vergrößerung lässt sich darauf schließen, dass die sich auf den Gleisen befindliche Frau die herannahende Straßenbahn wahrgenommen hat. Der Straßenbahnfahrer verzögert während der gesamten

<sup>188</sup> Aus Datenschutzgründen ist das Gesicht unkenntlich gemacht, insbesondere aus dem zeitlichen Kontext der Aufnahme lässt sich erschließen, dass die Frau eindeutig zur Straßenbahn schaut.

Vorbeifahrt mit  $a_{\text{Fahrer}} \approx -0,5 \text{ m/s}^2$  nur leicht. Das OuT reagiert zunächst aufgrund des ausreichenden Abstands bei geringer Ego-Geschwindigkeit nicht, obwohl sich die Frau im Fahrschlauch befindet. Noch während die Frau sich im Fahrschlauch befindet, wird diese aufgrund der ungenügenden Trennfähigkeit des Lidar-Clustering jedoch mit dem Kinderwagen, anderen Personen und dem Bauzaun zu einem Objekt zusammengefasst. Da entsprechend der Verhaltensplanung in Kapitel 4.4.7 nicht der Abstand zum Ort des Eintretens in den Fahrschlauch, sondern der nächste Objektpunkt zur Bahn (im Beispiel die nächste Ecke des Bauzauns) als Grundlage für die Berechnung der Sollbeschleunigung (siehe Abb. 4-16) verwendet wird, plant das OuT im dargestellten Zeitverlauf ab etwa 1,3 s eine maximale Bremsung, bis die Frau bei etwa 1,9 s den Fahrschlauch verlässt.

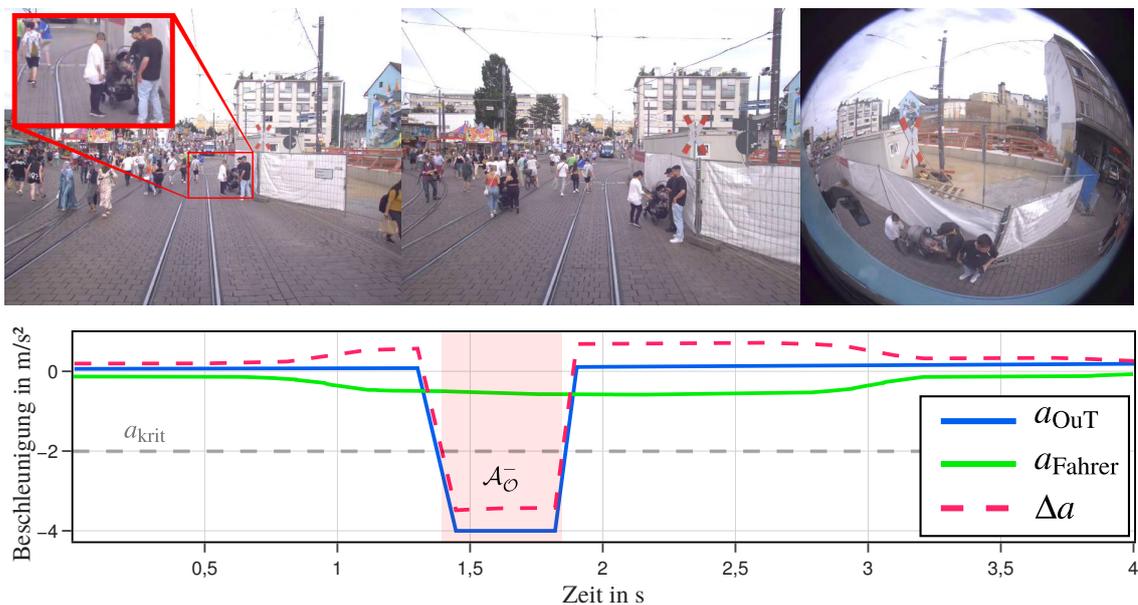


Abbildung 5-36: Beispiel II für Versagen aufgrund fehlender Intentionserkennung. Die Frau hat die Straßenbahn wahrgenommen und wird daraufhin wahrscheinlich den Fahrschlauch verlassen.

Bereits basierend auf der teilweise fehlenden Geschwindigkeit und damit ausbleibenden Bewegungsvorhersage von kreuzenden Fußgängern ist die zugehörige Hypothese  $\mathbf{H}_O10$  verifiziert. Darüber hinaus hat sich gezeigt, dass auch bei bekannter Geschwindigkeit und trotz Vorfahrtberechtigung der Straßenbahn eine Erkennung der Intentionen eines Objektes nicht ausreichend mit der Geschwindigkeit dieses Objektes bestimmt werden kann und fälschlich eine Reaktion ausgelöst wird.

Neben einer unzureichenden Intentionserkennung des Individualverkehrs (Pkw, Lkw, Fußgängern etc.) sind über die mikroskopisch betrachteten Schwerpunkte hinweg für den Innenstadtbereich mehrere  $\mathcal{A}_O^-$  identifiziert, die durch das Verhalten anderer Straßenbahnen und Busse ausgelöst werden. Insbesondere an für Bus und Straßenbahnen bzw. für Linien getrennten Haltestellen sowie an Kreuzungspunkten kommt es dazu, dass andere Fahrzeuge des ÖPNV anfahren oder

stehende Fahrzeuge überholen und dabei faktisch das Vorfahrtsrecht der Ego-Straßenbahn verletzen.

Wie nachfolgend in Abb. 5-37 gezeigt, reagieren die menschlichen Fahrer der Ego-Straßenbahn dabei je nach Szenario mit einer leichten Bremsung oder lassen mehrheitlich die Ego-Straßenbahn für kurze Zeit mit einer erhöhten Kritikalität bezüglich Abstand und Relativgeschwindigkeit rollen. Mutmaßlich ist diese geringe Reaktion darin begründet, dass das Verhalten andere Busse und Straßenbahnen im Linienbetrieb beim Verlassen der Haltestelle vom Menschen leicht zu antizipieren und präzisieren ist.



Abbildung 5-37: Beispiel kooperativer ÖPNV.

Es handelt sich somit um ein kooperatives Fahren des ÖPNV unter den menschlichen Fahrern. Für die umgesetzte Referenzimplementierung hingegen belegt ein (noch) langsames Objekt den Fahrschlauch. Wie für das oben gezeigte Beispiel mit der Frau und dem Kinderwagen, wird als Grundlage für die Bestimmung der Soll-Geschwindigkeit nicht der Abstand zum Ort des Eintretens in den Fahrschlauch verwendet, sondern der nächste Punkt des Objektes zur Bahn (im Beispiel das Heck des Busses). Folglich wird vom OuT im Vergleich zum menschlichen Fahrer eine stärkere Verzögerung geplant und es kommt zur Abweichung. Zwar existiert kooperatives Fahren auch im Kraftfahrzeugbereich,<sup>189, 190</sup> jedoch ist dies für den ÖPNV mit seinem Einsatz in der Innenstadt und dem Verhalten an Haltestellen ausgeprägter, weshalb es als Herausforderung für die Automatisierung des ÖPNV zu betrachten ist.

Die im Kapitel zuvor durchgeführte makroskopische Analyse hat gezeigt, dass es eine geringe Anzahl an  $\mathcal{A}_O^-$  gibt, bei der das OuT eine starke Verzögerung plant, während auch der Fahrer bereits stärker als gewöhnlich, wenn auch um  $a_{\text{krit}} = 2,0 \text{ m/s}^2$  weniger stark verzögert. Darauf basierend wurde die Hypothese  $\mathbf{H}_O11$  formuliert, demnach die Reaktion des OuT korrekt ist und die Abweichung unterschiedlicher Reaktionszeiten von Mensch und Maschine geschuldet sind. Dazu sind im Datensatz 16  $\mathcal{A}_O^-$  identifiziert und mikroskopisch betrachtet, bei denen der Fahrer bei Eintreten der Abweichung mit mindestens  $-1,5 \text{ m/s}^2$  verzögert. In 14 Fällen bremst das OuT fälschlich für Dachkanten von Fahrgastunterständen oder für aufgrund von Blooming vermeintlich in den Fahrschlauch ragende Verkehrsschilder, während der menschliche

189 Dolk, V. et al.: Cooperative Automated Driving Scenarios (2018).

190 Llatser, I. et al.: Cooperative Automated Driving Use Cases (2019).

Fahrer lediglich etwas später und damit stärker jedoch noch regulär für den Halt an einer Haltestelle bremst. In den verbleibenden Fällen handelt es sich jedoch um Szenarien mit erhöhter Kritikalität, bei denen Fahrer und OuT mit einer starken Verzögerung zu unterschiedlichen Zeitpunkten reagieren. Eines dieser Szenarien ist nachfolgend in Abb. 5-38 gezeigt. Ein Pkw auf dem benachbarten Fahrstreifen fährt über die durchgezogene Fahrbahnmarkierung und wendet über den besonderen Bahnkörper hinweg. Neben dem Beschleunigungsverlauf ist nachfolgend in — mit einer zweiten Ordinatenachse (rechts) zusätzlich die Auslenkung des Fahr-Brems-Sollwertgebers zur Anzeige des Vorhabens des Fahrers in Prozent gezeigt. Dabei entsprechen positive Werte einer Auslegung nach vorne, also der Anforderung einer Zugkraft während die Auslenkung nach hinten mit negativen Werten im Diagramm dargestellt ist und die Anforderung einer Bremskraft entspricht. Entsprechend Abb. 5-38 reagieren Fahrer und OuT nahezu zeitgleich bei etwa 1,0–1,2 s. Der Fahrer fordert jedoch zunächst nur etwa -60 % Bremskraft an, weshalb es zur  $\mathcal{A}_O^-$  kommt. Kurz darauf ist der Pkw bereits wieder aus dem Fahrschlauch, das OuT bricht den Bremsvorgang ab, doch der Fahrer löst noch eine sogenannte „Gefahrenbremsung“<sup>191</sup> bei etwa 2,6 s aus, weshalb es anschließend sogar zu einem  $\mathcal{A}^+$  kommt, welches in Kapitel 5.5 aufgegriffen wird.

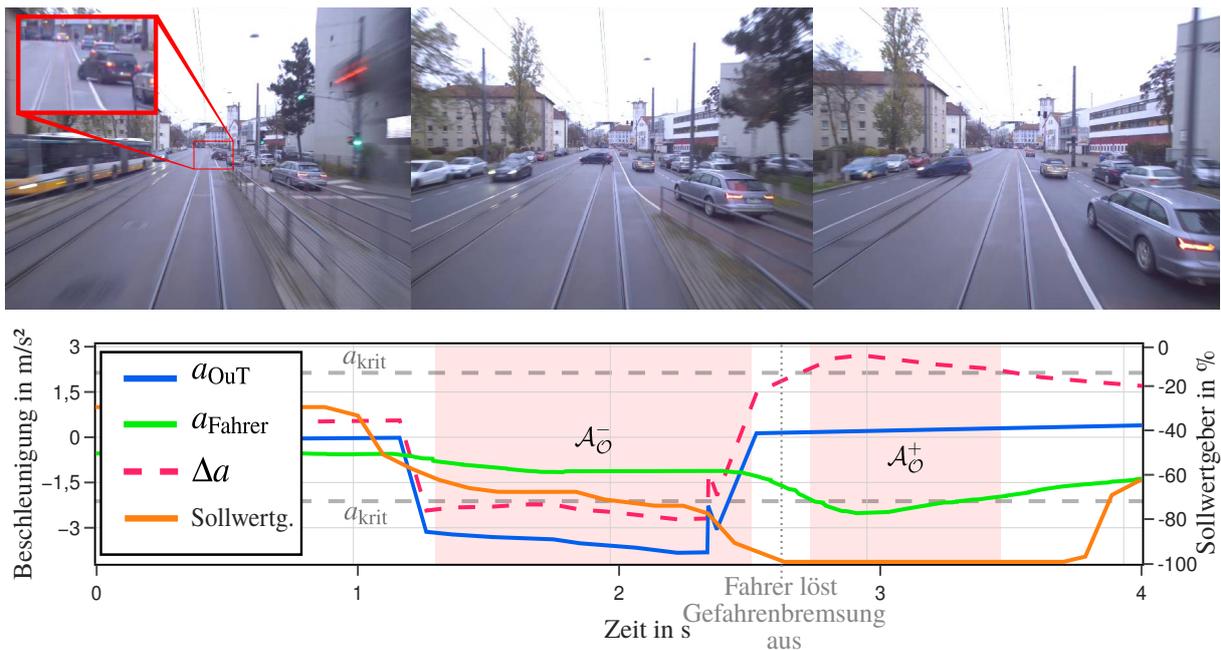


Abbildung 5-38: Beispielszenario für den Einfluss der Reaktionszeiten. Fahrer und System reagieren bei etwa 35 m Entfernung und 50 km/h nahezu zeitgleich, jedoch fordert der Fahrer zunächst nur eine geringe Bremskraft an, weshalb es zur Abweichung kommt.

Auch wenn nur ein Fall identifiziert ist, gilt die Hypothese  $\mathbf{H}_O11$  als verifiziert. Die Aussage der Hypothese muss für sprunghafte Anforderungen der Bremse jedoch erweitert werden, da die obige Abb. 5-38 nicht nur unterschiedliche Reaktionszeiten zwischen OuT und Mensch zeigt, sondern auch Verzugszeiten im Aufbau der realen Verzögerung durch die endliche Dynamik

191 Erläuterung folgt im Rahmen der  $\mathcal{A}^+$

der Straßenbahn. Da der Einfluss der Reaktionszeit —ausgenommen des Eingangs erklärten unterschiedlichen Anfahrverhaltens — jedoch nur für besonders starke Bremsungen relevant ist, ist der Einfluss auf die Anwendung von *Silent Testing* als gering zu bewerten ist.

In der vorangegangenen makroskopischen Analyse ist basierend auf Abb. 5-17 für die Verteilung der Beschleunigungen des OuT über denen des Fahrers eine Anhäufung von Abweichungen aufgezeigt. Die Anhäufung charakterisiert sich dadurch, dass der menschliche Fahrer die Straßenbahn mit  $a_{\text{Fahrer}} \approx 0,0 \text{ m/s}^2$  rollen lässt, während das OuT bereits um mindestens  $a_{\text{krit}}$  verzögert. Basierend hierauf wurde die Hypothese  $\mathbf{H}_{\text{O}12}$  formuliert, dass der menschliche Fahrer in uneindeutigen Szenarien zunächst abwartet, während das OuT bereits eine Verzögerung plant. Dazu sind im Datensatz 40  $\mathcal{A}_{\text{O}}$  mikroskopisch betrachtet, bei denen der menschliche Fahrer die Straßenbahn um  $\pm 0,2 \text{ m/s}^2$  rollen lässt. In keinem der betrachteten Fälle ist das Verhalten jedoch auf die in  $\mathbf{H}_{\text{O}12}$  formulierte Vermutung zurückzuführen. In allen Fällen handelt es sich um Abweichungen bedingt durch Blooming, Vegetation, unzureichende Erkennung einer Kreuzungsabsicht, zu frühen Reaktion aufgrund fehlender Lidar-Cluster Trennfähigkeit und somit falscher Bestimmung des Abstandes oder andere Ursachen, die bereits in diesem Kapitel aufgezeigt sind. Die zugehörige Hypothese  $\mathbf{H}_{\text{O}12}$  ist somit nicht verifiziert.

Die Beschleunigungen des Fahrers sind in den betrachteten  $\mathcal{A}_{\text{O}}$  jedoch nur zufällig  $\approx 0,0 \text{ m/s}^2$ . Aus der mikroskopischen Betrachtung dieser und anderer Messreihen in diesem Kapitel geht hervor, dass menschliche Fahrer zum Halten einer gewünschten Geschwindigkeit häufig stoßweise kurz beschleunigen, die Straßenbahn rollen lassen und dann wieder beschleunigen, wie es nachfolgend als Ausschnitt in Abb. 5-39 gezeigt ist. Erneut ist neben dem Beschleunigungsverlauf in — zusätzlich die Auslenkung des Fahr-Brems-Sollwertgebers gezeigt, die entgegen obiger Abb. 5-38 in dem hier dargestellten Fall nur eine positive Auslenkung also die Anforderung einer Zugkraft zeigt.

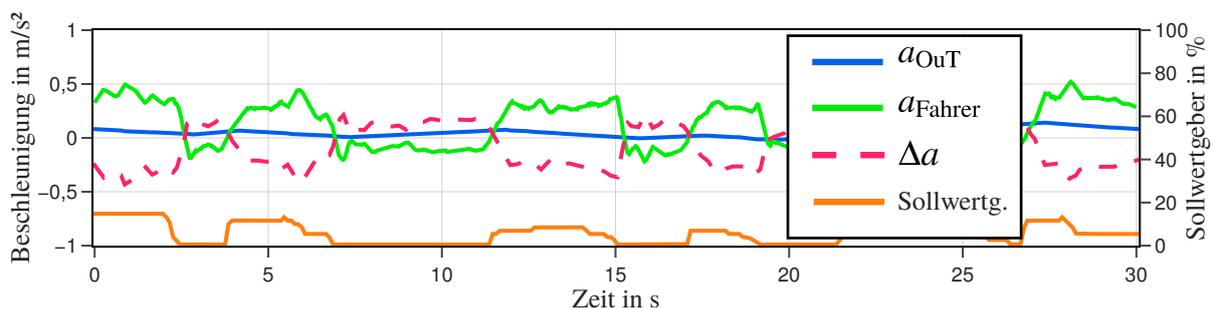


Abbildung 5-39: Geschwindigkeitsregelung des menschlichen Fahrers. Der gezeigte Ausschnitt zeigt eine hindernisfreie Fahrt auf gerader Strecke, wobei der Fahrer mit dem gezeigten Verhalten etwa  $30 \text{ km/h}$  hält.

Die 30 makroskopisch gebildeten Hotspots sind zuvor im Rahmen der verschiedenen Hypothesen oder zugehörigen Themen bereits alle aufgeführt. Nachfolgend sind in Tabelle 5-3 die fünf verschiedenen Gründe nochmals zusammengefasst:

Tabelle 5-3: Ursachen  $\mathcal{A}_O^-$  Hotspots.

	Blooming	Vegetation	Bodenfilter	Straßenna- mensschild	Fahrgastun- terstand
<b>Anzahl Hotspots</b>	13	9	4	2	2

Neben den oben aufgeführten Gründen der Hotspots, aber auch der anderen mikroskopisch betrachteten und bereits erläuterten  $\mathcal{A}_O^-$  sind vereinzelt weitere Ursachen identifiziert. Diese nachfolgend erläuterten Gründe für Abweichungen gelten zwar als identifiziertes Problem im Sinne der erfolgreichen Anwendung von *Silent Testing*, sind jedoch aufgrund der geringen Anzahl und einfachen Lösungsmöglichkeiten nicht als Herausforderung der Automatisierung von Straßenbahnen zu betrachten:

- **Vögel:** Im Bereich der Innenstadt sowie auf Überlandfahrten sind mehrere Messreihen identifiziert, bei denen Vögel im Nahbereich vor der Bahn fliegen und eine  $\mathcal{A}_O^-$  verursachen. Insbesondere bei ausgebreiteten Flügeln weisen die Objekte Höhen bis über 30 cm auf, die beispielhaft in Anhang B.9 abgebildet sind. Zur Vermeidung falsch positiver Bremsreaktionen sind zukünftig Filterkaskaden denkbar, die Höhe über Boden, Größe, Dynamik und Lebensdauer berücksichtigen.
- **Falsche Geschwindigkeiten bei entgegenkommenden ÖPNV:** Wie bereits im Rahmen der Referenzimplementierung in Kapitel 4.4.5 beschrieben, bilden die eingesetzten Radare aufgrund fehlender — jedoch grundsätzlich technologisch möglicher — Objekthypothesen für Straßenbahnen und Busse diese als mehrere Pkw ab, deren Boundingboxen jedoch über das reale Objekt hinausragen. Vereinzelt sind Messreihen identifiziert, bei denen während einer Folgefahrt (Ego-Straßenbahn fährt hinter anderem Fahrzeug) und dem gleichzeitigen Entgegenkommen einer anderen Straßenbahn oder eines Busses die Geschwindigkeit des entgegenkommenden Objektes als Teil der Fusion fälschlich dem vorausfahrenden Objekt zugeordnet wird. Ausgelöst hierdurch wechselt die Verhaltensplanung von einer Regelung der Folgefahrt zu einer starken Bremsung für ein entgegenkommendes Objekt. Zur Vermeidung falsch positiver Bremsreaktionen sind zukünftig verschiedene Verbesserungen denkbar: So könnten einerseits Radare verwendet werden, die auch Objekthypothesen für Straßenbahnen und Busse unterstützen. Auch zusätzliche Plausibilitätsüberprüfungen bei der Aktualisierung der  $\mathcal{O}_{\text{track}}$ , wie z. B. eine Begrenzung der Geschwindigkeitsänderung innerhalb einer gewissen Zeitspanne, sind denkbar. Andererseits würde auch eine *Low-Level-Fusion* auf Detektionsebene statt der hier umgesetzten *High-Level-Fusion* auf Objektlistenebene diese Fehler reduzieren können.

### 5.4.3 $\mathcal{A}_O^-$ Teilevaluation

In folgendem Teilabschnitt werden die identifizierten  $\mathcal{A}_O^-$  bezüglich der Automatisierung von Straßenbahnen und der Anwendung von *Silent Testing* eingeordnet. Zunächst wird nachfolgend eingeordnet, welche umgesetzten straßenbahnspezifischen Möglichkeiten zur Vereinfachung der Automatisierung nicht als Ursache von  $\mathcal{A}_O^-$  identifiziert sind und somit zwar nicht validiert, jedoch plausibilisiert sind. Da ein Großteil der falsch positiven Bremsreaktionen durch Lidar bzw. die Verarbeitung der Punktwolke bedingt ist, wird dies nachfolgend gesondert bewertet und mögliche Lösungsansätze aufgezeigt.

#### Plausibilisierte Möglichkeiten zur Vereinfachungen im Kontext der $\mathcal{A}_O^-$

Für die Einordnung der Kritikalität der Objekte ist im Rahmen der Referenzimplementierung der Abstand des Objektes zur Schiene als Diskriminator festgelegt. Auch wenn die mikroskopische Untersuchung aufgedeckt hat, dass die umgesetzte Intentionserkennung nicht ausreichend ist, so ist kein Gegenbeispiel identifiziert, weshalb Objekte basierend auf Karten- oder Lokalisierungsfehlern fälschlich in den Fahrschlauch ragen. Somit ist einerseits die grundsätzliche Nutzung der Schiene als Diskriminator, wenn auch mit erforderlicher Verbesserung hinsichtlich der Intentionserkennung plausibilisiert. Andererseits ist der kartenbasierte Abruf des mit Segmenten und Splines modellierten Gleisverlaufs in Kombination mit der GNSS- und odometriebasierten Lokalisierung (Position und Orientierung) nicht als Ursache für Abweichungen identifiziert. Demzufolge gilt die Vereinfachung als Alternative zur kamerabasierten Bestimmung des Gleises als plausibilisiert.

Es muss jedoch beachtet werden, dass nicht alle  $\mathcal{A}_O^-$  mikroskopisch ausgewertet sind und somit mögliche, wenn auch seltene Fehlerquellen nicht aufgedeckt sein können und die Verfahren daher nur plausibilisiert und insbesondere nicht statistisch validiert sind.

#### Lidar Clustering und Auswahl der Objekte im Kontext der $\mathcal{A}_O^-$

Der Großteil der Ursachen für  $\mathcal{A}_O^-$  ist mit in den Fahrschlauch ragender Vegetation, Blooming an Verkehrsschildern, Fehldetektion aufgrund zu naher Oberflächen etc. auf Objekte zurückzuführen, die in der Realität kein wirkliches Hindernis darstellen. Dabei sind die Fehler sowohl durch die Verarbeitung der Punktwolke in Form des genutzten Clusterings wie auch durch inkorrekte Detektionen (Blooming, Nebel) bedingt. Insbesondere aufgrund der Nähe zu realen Objekten die keine Hindernisse sind (Verkehrsschilder, Vegetation etc.), der Häufigkeit solcher nahen Objekte sowie der fehlenden Möglichkeit diesen auch bei einer frühzeitigen Wahrnehmung lateral auszuweichen zu können, sind diese Ursachen als besondere Herausforderungen für die Automatisierung von Straßenbahnen zu bewerten.

Darüber hinaus sind mit der erfolgreichen Anwendung von *Silent Testing* Fehler der sensorbasierten Wahrnehmung identifiziert, die in gleichem Maße auch für die Automatisierung von Kraftfahrzeugen relevant sind. Fälschliche Lidar Detektion oder gar dahinter liegende, nicht

wahrgenommene reale Hindernisse bedingt durch Nebel oder die fehlende Trennfähigkeit von Objekten sind ebenfalls Herausforderungen des Kraftfahrzeugbereichs.

Als Alternative zu konventionellem Lidar-Clustering gelten maschinell gelernte Detektionsverfahren. Diese könnten durch ihre Funktionsweise und die damit gezielte „Suche“ nach Merkmalen von Personen, Pkw, Straßenbahn etc. in der Punktwolke insbesondere die aufgezeigten Probleme bedingt durch Vegetation, fehlende Trennfähigkeit sowie Versagen des Bodenfilters reduzieren. Darüber hinaus sind auch die im vorherigen Kapitel mikroskopisch aufgezeigten Probleme der Fehldetektion von Objekten aufgrund von Blooming oder zu naher Oberflächen durch maschinell gelernte Detektionsverfahren reduzierbar. Das gelingt, indem die Detektionen aufgrund fehlender Merkmale zu bekannten Objektklassen schlichtweg ignoriert oder solche Effekte gezielt als Teil der Trainingsstrategie erkannt und im Rahmen der Anwendung als bspw. erkanntes Blooming bewusst verworfen werden. Demgegenüber gilt für maschinell gelernte Lidarobjektdetektoren, wie bereits im Rahmen des Entwurfs zur Referenzimplementierung in Kapitel 4.3.2 aufgezeigt, dass der Sicherheitsnachweis im Gegensatz zu analytischen Verfahren wie Clustering deutlich erhöht und nicht vollständig gelöst ist. Darüber hinaus stellt aufgrund unterschiedlicher Auflösungen, Sensorpositionen sowie weiteren immanenten Eigenschaften wie Reichweite, Rauschverhalten etc. der Domänentransfer gelernter Methoden für Lidar eine noch ungelöste Herausforderung dar.<sup>192</sup>

Hieraus ergibt sich für maschinell gelernte Lidar Detektoren ein Bedarf an ausreichend<sup>193</sup> annotierten Lidar Daten der Domäne Straßenbahn unter Nutzung der für den Produktiveinsatz vorgesehen Sensoren für das Training solcher Detektoren. Aufgrund fehlender öffentlicher Datensätze, des geringen Volumens an automatisierbaren Straßenbahnen im Gegensatz zu Kraftfahrzeugen sowie örtlichen Besonderheiten der verschiedenen Straßenbahnnetze sind diese Nachteile für Straßenbahnen jedoch deutlich ausgeprägter als für Kraftfahrzeuge. Weiterhin ergeben sich verschiedene Möglichkeiten, auch ohne maschinell gelernte Detektoren die im Kapitel zuvor aufgezeigten Ursachen für falsch positive Reaktionen zu reduzieren. Dabei muss insbesondere beachtet werden, dass diese Arbeit die erste Umsetzung der Automatisierung im Rahmen einer Forschungsarbeit darstellt, deren in Kapitel 4.3 aufgezeigte Prämisse eine Automatisierung mit zunächst möglichst geringer Komplexität ist. Weitere Verbesserungen zu den bestehenden einfachen Auswertemethoden der Objektdetektion und des Objekttrackings sind jedoch nicht Teil dieser Arbeit, sondern sind nachfolgend nur als mögliche Ansätze aufgezeigt:

- **kartenbasierte Filter:** An Stellen bekannter Einschränkung wie den Fahrgastunterständen oder LSA, die zu nah an den Sensoren sind, aber auch Stellen, an denen die 2D Überprüfung hinsichtlich der Belegung des Fahrschlauches für hohe Objekte fehlschlägt wie z. B. für die aufgezeigten Straßennamensschilder sind kartenbasierte Filter denkbar. Diese könnten auf Basis der bestehenden Karte und Referenzierung anhand der Splines gezielt

192 Triess, L. T. et al.: A Survey on Deep Domain Adaptation for LiDAR Perception (2021), S. 352.

193 Im Sinne des Sicherheitsnachweises und Vollständigkeit der zu detektierenden Objekte.

Detektionen vor dem Clustering entfernen. In ähnlicher Umsetzung sind auch Filter für durch Blooming verursachte Detektionen an bekannten Verkehrsschildern sowie örtlich angepasste Parameter für den Bodenfilter denkbar.

- **FMCW Lidar:** Die in dieser Arbeit genutzten Lidarsensoren beruhen auf dem bisher mehrheitlich für Lidarsensoren genutzten *Time of Flight* (ToF) Prinzip. Moderne, in der Entwicklung und in ersten prototypischen Applikationen befindliche Lidare nutzen ähnlich wie Radarsensoren das sogenannte *Frequency Modulated Continuous Wave* (FMCW) Prinzip, welches bisher aus Kosten- und Komplexitätsgründen nicht für Lidar genutzt worden ist. Neben reduziertem Einfluss von anderen Sensoren, Sonnenlicht etc. bietet FMCW den wesentlichen Vorteil der integrierten Geschwindigkeitsmessung.<sup>194</sup> Dies ermöglicht eine Trennung von Objekten basierend auf der Geschwindigkeit, wodurch die in dieser Arbeit aufgezeigten Probleme der Trennfähigkeit von Objekten reduziert werden können. Auch wenn es noch nicht ausreichend erforscht ist, verspricht FMCW Lidar darüber hinaus einen reduzierten Einfluss von Nebel und Regen.<sup>195</sup> Aufgrund der integrierten Geschwindigkeitsmessung bietet FMCW Lidar (ohne weitere Prüfung auf Redundanzen etc.) die Möglichkeit, auf Radarsensoren zu verzichten.
- **Filter auf Objektebene:** Wie die makroskopische Analyse zeigt, sind die meisten falsch positiven Reaktionen sowohl von kurzer Dauer (Median 0,6 s) wie auch kurzer Lebensdauer der Objekte (Median 2,0 s) geprägt. Hinzu kommt, dass es als erste konservative Auslegung keine Mindestlebensdauer für Objekte gibt und es wie für die mehrfach aufgezeigte am Wagenkasten der Straßenbahn schleifende Vegetation bereits ausreicht, dass Objekte auch bei weiterer Entfernung nur minimal in den Fahrschlauch ragen. Unter Berücksichtigung verschiedener weiterer Parameter wie detektierte Klasse, der Höhe des Objektes, Höhe über Boden, der Geschwindigkeit, der Kritikalität des Objektes, maschinell gelernte kamerabasierte Vegetationserkennung etc. sind verschiedene Filter denkbar, die Phantomobjekte reduzieren, ohne die Dynamik für Szenarien mit erhöhter Kritikalität zu beeinträchtigen.
- **Verbesserte Fusion und Tracking:** Durch den Perspektivwechsel versagte die zuverlässige zeitliche Verfolgung von entgegenkommenden Straßenbahnen und Bussen. Die umgesetzte Fusion und der Trackingalgorithmus sind aufgrund der einfachen Umsetzung nicht ausreichend. Vornehmlich Detektionslücken, Abschattungen und Veränderungen der Form (aufgrund der Gelenke von Bussen und Straßenbahnen) haben zu falschen Bewegungsschätzungen geführt. Das genutzte Modell zur konstanten Geschwindigkeit bildet insbesondere die Kurvenfahrt unzureichend ab. Eine Verbesserung der Fusion und des Trackings diesbezüglich ist eine weitere Möglichkeit zur Reduzierung von falsch positiven Reaktionen.

---

194 Sayyah, K. et al.: Fully Integrated FMCW LiDAR Engine (2022).

195 Zhu, C. et al.: Influence of haze on FMCW laser (2019).

## Intentionserkennung der Objekte im Kontext der $\mathcal{A}_O^-$

Im Rahmen der Referenzimplementierung wird nur eine mögliche Bewegung aus dem Fahrschlauch heraus zur Vermeidung von falsch positiven Bremsreaktionen betrachtet. Die vorangegangene Betrachtung der  $\mathcal{A}_O^-$  evaluiert bezüglich der Intentionserkennung auch nur die Vorhersage zum Verlassen des Fahrschlauches. Mögliche Unzulänglichkeiten hinsichtlich einer fehlerhaft ausbleibenden Situation bezüglich zukünftigem Eintreten in den Fahrschlauch sind Teil der  $\mathcal{A}^+$  Betrachtung des folgenden Kapitel 5.5. Die umgesetzte Vorhersage basiert auf einer einfachen Erkennung zur Absicht des Kreuzens der Gleise anhand der Geschwindigkeit wie es in Kapitel 4.4.7 beschrieben ist. Die mikroskopische Betrachtung hat gezeigt, dass im Rahmen der Fusion insbesondere bei querenden Fußgängern die Geschwindigkeit fehlt und eine  $\mathcal{A}_O^-$  ausgelöst wird. Einerseits ist dies wegen der querenden Richtung und damit des fehlenden Dopplereffektes sowie wegen der geringen Radarreflexionen von Menschen eine technologische Schwierigkeit, die zumindest für den fehlenden Dopplereffekt in ähnlicher Weise auch für FMCW Lidare gilt. Andererseits ist aufgrund der genannten Schwächen bezüglich der Detektionen von Straßenbahnen und Bussen davon auszugehen, dass die eingesetzten Radare auch nicht für die Detektion von Fußgängern optimiert sind. Als mögliche Lösung könnte die querende Geschwindigkeit —ähnlich wie es im genutzten Radar intern bereits erfolgt— durch eine aufwendigere modellbasierte Schätzung anhand der Positionsänderung eines stabilen sogenannten *Tracking Points*<sup>196</sup> mittels Lidar geschätzt werden.

Neben einem Fehlen der Geschwindigkeit für darauf basierende eindeutig vorherzusagende Absichten des Kreuzens haben mehrere  $\mathcal{A}_O^-$  gezeigt, dass auch bei bekannter Geschwindigkeit diese nicht ausreicht, um die Intention mehrerer Objekte ausreichend vorherzusagen. Trotz eigentlicher Vorfahrtberechtigung der Straßenbahn kann der Verzicht auf eine komplexere Intentionserkennung nicht als vereinfachende Möglichkeit zur Automatisierung von Straßenbahnen genutzt werden. Vielmehr ist eine Erkennung der Intentionen anderer Verkehrsteilnehmer zum Verlassen des Fahrschlauches für die Automatisierung von Straßenbahnen wie auch für die Automatisierung des Kraftfahrzeugbereichs eine besondere Herausforderung.

Als eigentümliche Besonderheit der Automatisierung des ÖPNV ist die im Rahmen der mikroskopischen Analyse aufgezeigte kooperative Fahrweise des ÖPNV zu bewerten. Als Lösungsansatz für einen Einsatz der Automatisierung in einem Mischbetrieb aus menschlichem Fahrer und Maschine könnte dies zwar auch durch Anpassung der menschlichen Fahrweisen erfolgen, dennoch ist, wie oben aufgezeigt, eine verbesserte Intentionserkennung erforderlich, die auch die Absicht anderer Fahrzeuge des ÖPNV berücksichtigen könnte.

## **Silent Testing** im Kontext der $\mathcal{A}_O^-$

Die Anwendung von *Silent Testing* mittels Vergleich der Beschleunigungen von menschlichem Fahrer und OuT hat für die vorliegende Referenzimplementierung korrekterweise eine Vielzahl

<sup>196</sup> Xie, D. et al.: Obstacle detection and tracking based on LiDAR (2019).

von  $\mathcal{A}_O^-$  identifiziert. Aufgrund der Vielzahl ist eine manuelle Auswertung jeder Abweichung unverhältnismäßig. Durch die makroskopische Analyse sind daher Stellvertreter für eine manuelle Untersuchung ausgewählt. Mit diesen und folglich mit *Silent Testing* sind straßenbahnspezifische sowie allgemeine Herausforderungen der Automatisierung, aber auch Unzulänglichkeiten im Sinne einer grundlegenden Verifikation der Referenzimplementierung aufgezeigt. Aufgrund der Menge der Abweichungen geht jedoch hervor, dass *Silent Testing* als iterativer Prozess nach einer Verbesserung der aufgezeigten Ursachen für die Abweichungen erneut anzuwenden ist. Die in dieser Arbeit aufgezeigten Herausforderungen der Objektdetektion sind somit als die wesentlichen Besonderheiten der Straßenbahnautomatisierung zu betrachten, jedoch ist aufgrund der Vielzahl der in dieser Arbeit identifizierten  $\mathcal{A}_O^-$  davon auszugehen, dass auch weitere Herausforderungen der Automatisierung von Straßenbahnen durch *Silent Testing* identifiziert werden könnten.

Weiterhin verursachen unterschiedliche Reaktionszeiten zwischen Mensch und Maschine bei Gefahrensituationen teilweise falsch positive  $\mathcal{A}_O^-$ , die in Wirklichkeit keine relevante Abweichung darstellen, jedoch treten diese einerseits selten auf, weshalb dies akzeptabel ist. Andererseits bergen insbesondere Gefahrensituationen das Potenzial die Automatisierung für besonders kritische Szenarien mikroskopisch zu evaluieren und ggf. zu verbessern.

## 5.5 $\mathcal{A}^+$ Abweichungen

Mit der obigen Analyse der  $\mathcal{A}^-$  aller Kategorien sind alle Abweichungen betrachtet, bei denen das OuT stärker verzögert hat als der menschliche Fahrer. Im folgenden Teilabschnitt werden als Gegenstück dazu die  $\mathcal{A}^+$  untersucht. Wiederholend zur Tabelle, die zu Beginn dieses Hauptkapitels gezeigt ist, fasst Tabelle 5-4 erneut die Anzahl der identifizierten  $\mathcal{A}^+$  zusammen. Dabei sind die Abweichungen nach dem zu diesem Zeitpunkt aktiven Modul der Verhaltensplanung des OuT aufgetrennt.

Tabelle 5-4: Identifizierte  $\mathcal{A}^+$  basierend auf dem zu diesem Zeitpunkt aktiven Modul der Verhaltensplanung.

	Lichtsignal- anlagen	Haltstellen	Höchstgeschwin- digkeit	Objekte
$\mathcal{A}^+$	0	2	1.335	19

Wie bereits erwähnt, gilt für  $\mathcal{A}^+$  jedoch nicht der Zusammenhang wie für  $\mathcal{A}^-$ , dass das aktive Verhaltensmodul auch die Ursache für die Abweichung ist. Vielmehr ist aufgrund von häufiger Hindernisfreiheit, keiner anstehenden Haltestelle oder LSA zeitlich betrachtet meist die Regelung zur Einhaltung der Höchstgeschwindigkeit aktiv. Aus diesem Grund treten mit absoluter Mehrheit die  $\mathcal{A}^+$  auch in dieser Kategorie auf, wobei die Begründungen für das menschliche Verhalten

und Auslösen der Abweichung vielfältig sein können. Aufgrund der Vielzahl der Abweichungen ist ähnlich der  $\mathcal{A}_{LSA}^-$  und  $\mathcal{A}_O^-$  eine manuelle Auswertung aller  $\mathcal{A}^+$  unverhältnismäßig. Aus diesem Grund erfolgt auch hier eine Auswahl von Stellvertretern für eine manuelle Auswertung im Rahmen einer makroskopischen Auswertung.

### 5.5.1 $\mathcal{A}^+$ Makroskopische Betrachtung

Obwohl der Zusammenhang nicht eindeutig ist, lässt sich vermuten, dass die 19  $\mathcal{A}^+$  mit aktiver Verhaltensplanung zu Objekten tatsächlich durch Objekte sowie die 2  $\mathcal{A}^+$  mit aktiver Verhaltensplanung zu Haltestellen tatsächlich durch Haltestellen begründet sind. Aufgrund der geringen Anzahl werden alle 21 Messreihen im anschließenden Teilabschnitt mikroskopisch betrachtet. Im Folgenden werden daher nur die 1.335  $\mathcal{A}_{v_{max}}^+$  mit aktiver Verhaltensplanung zur Einhaltung der Höchstgeschwindigkeit makroskopisch ausgewertet. Wie bei der makroskopischen Analyse der  $\mathcal{A}^-$  werden auch in diesem Kapitel Hypothesen zur Ursache der Abweichung aufgestellt und anschließend mit den Ergebnissen der mikroskopischen Analyse verglichen.

Zur Überprüfung der Kritikalität der Abweichungen ist nachfolgend links in Abb. 5-40 (a) die Verteilung der minimal aufgetretenen Beschleunigungen des menschlichen Fahrers als eCDF sowie nachfolgend rechts in Abb. 5-40 (b) die geplante Beschleunigung des OuT über der Beschleunigung des Fahrers bei Eintreten der Abweichung dargestellt. Dabei wird in beiden Darstellungen mit ● gekennzeichnet, ob der Fahrer innerhalb der Dauer der Abweichung eine sogenannte „Gefahrenbremsung“ ausgelöst hat. Diese ist nach BOStrab und den drauf aufbauenden Regelungen<sup>197, 198</sup> eine besondere Raststellung des Fahr-Brems-Sollwertgebers, die eine maximale Verzögerung inkl. Magnetschienenbremse auslöst. Die Auslösung einer Gefahrenbremsung ist somit ein besonderer Indikator für kritische Szenarien.

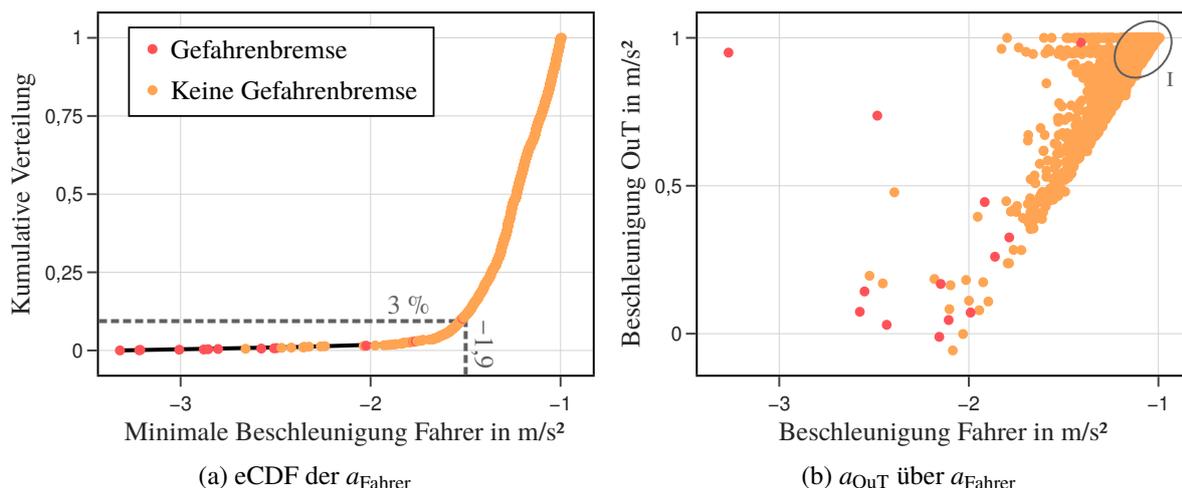


Abbildung 5-40:  $\mathcal{A}_{v_{max}}^+$  Verteilung der Beschleunigungen. ● kennzeichnet, dass der Fahrer während der Abweichung eine Gefahrenbremsung ausgelöst hat.

197 VDV: Technische Regeln Bremsen (2008).

198 DIN EN 13452: Bremssysteme des öffentlichen Nahverkehrs (2005).

Die Betrachtung der minimalen Beschleunigungen in Abb. 5-40 (a) zeigt, dass es einige wenige starke Bremsungen gibt, wobei es sich dabei nicht ausschließlich um Gefahrenbremsungen handelt. Aufgrund dieser vermeintlich kritischen Szenarien und der dabei ausbleibenden oder verspäteten Reaktion des OuT wird folgende Hypothese als mögliche Ursache aufgestellt:

**Hypothese 1 ( $H_{+1}$ ):** *Stellenweise plötzlich auftretende Hindernisse mit besonders hoher Kritikalität werden vom OuT zu spät bzw. nicht erkannt oder die Verhaltensplanung reagiert nicht angemessen mit einer Bremsung.*

Zur Verifikation dieser Hypothese sind im nachfolgenden Kapitel etwa 3 % aller Messreihen mikroskopisch betrachtet, bei denen der Fahrer mit  $-1,9 \text{ m/s}^2$  oder stärker verzögert. Dabei entspricht dieser Wert der geringsten Verzögerung die als Gefahrenbremsung identifiziert ist. Als Grund für die Streuung der maximalen Beschleunigung während einer Gefahrenbremsung werden mutmaßlich Schwankungen des maximalen Bremsvermögens aufgrund von Witterung, Schmierfilm etc. angenommen, dies ist jedoch makroskopisch nicht zu verifizieren.

Im Kapitel 3.3.3 ist im Rahmen der Parametrierung von  $a_{\text{krit}}$  aufgezeigt, dass die menschlichen Fahrer bei dem vergleichsweise einfachen Szenario des Losfahrens von einer außerhalb des öffentlichen Straßenverkehrs gelegenen Haltestelle bereits um bis zu  $1,5 \text{ m/s}^2$  unterschiedliches Bremsverhalten aufweisen. Sowohl obige Abb. 5-40 (a) wie auch Abb. 5-40 (b) zeigen, dass der menschliche Fahrer während den meisten Abweichungen mit einer absolut betrachtet geringen Verzögerung bremst und dieser Vorgang somit nicht kritisch ist. Es lässt sich also einerseits vermuten, dass ein großer Teil der  $\mathcal{A}_{v_{\text{max}}}^+$  nur durch eine Varianz des menschlichen und damit im Rahmen von *Silent Testing* als „richtiges“ Fahrverhalten begründet ist.

**Hypothese 2 ( $H_{+2}$ ):** *Aufgrund der Varianz des menschlichen Verhaltens und der gewählten Metrik zur Identifikation von Abweichungen mit  $|\Delta a| > a_{\text{krit}}$  sowie der Parametrierung von  $a_{\text{krit}}$  werden falsch positive Abweichungen identifiziert, die nicht kritisch sind.*

Andererseits lässt sich auch eine besonders vorausschauende Fahrweise des menschlichen Fahrers vermuten, die im Rahmen der Referenzimplementierung nicht umgesetzt ist. Aus diesem Grund ist nachfolgende Hypothese formuliert und zugehörige stellvertretende einzelne Messreihen mikroskopisch untersucht. Dazu sind 40 zufällige Messreihen aus dem in Abb. 5-40 (b) mit **I** markierten Bereich ausgewählt.

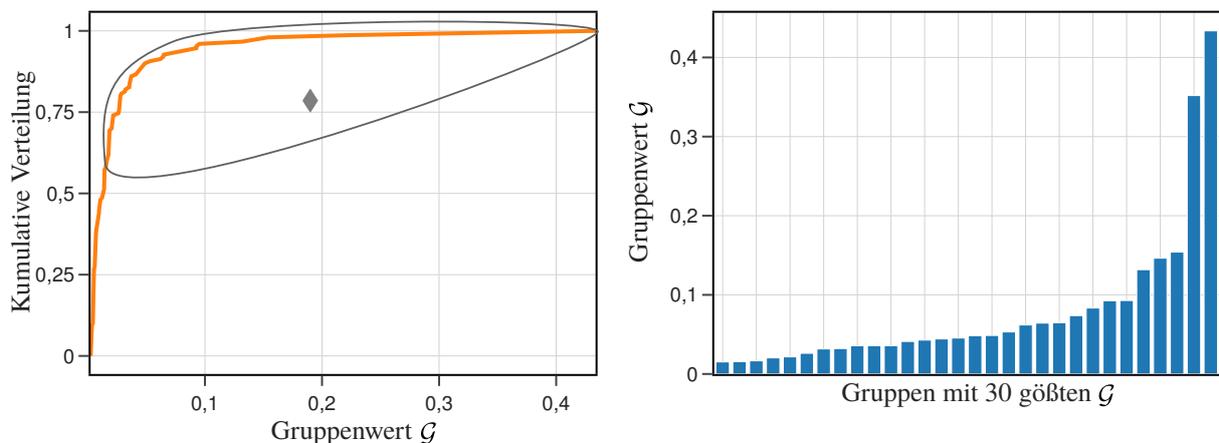
**Hypothese 3 ( $H_{+3}$ ):** *Aufgrund einer vorausschauenden Fahrweise des menschlichen Fahrers bremst dieser für einige Hindernisse bereits vergleichsweise früh und damit weniger stark.*

Im Gegensatz zu der makroskopischen Betrachtung der  $\mathcal{A}^-$  kann für die  $\mathcal{A}_{v_{\text{max}}}^+$  keine statistische Auswertung von Eigenschaften der auslösenden Verhaltensplanung wie eine Analyse der Objekthöhen oder der Schaltzustände von LSA erfolgen, da der Grund für die Abweichung unbekannt ist. Daher werden als abschließende makroskopische Betrachtung im Folgenden erneut 30 Hotspots gebildet, ähnlich wie es in Kapitel 5.4 für die  $\mathcal{A}_{\bar{0}}$  erfolgt ist.

Als maximaler Abstand ist erneut  $d_{\text{hspot}} = 3$  m als erster Schätzwert zur Bildung von Gruppen gewählt. Eine  $\mathcal{A}_{v_{\text{max}}}^+$  muss daher zu mindestens einer anderen  $\mathcal{A}_{v_{\text{max}}}^+$  einen Abstand von weniger als  $d_{\text{hspot}}$  aufweisen, um einer bestehenden Gruppe zugeordnet zu werden oder eine neue Gruppe zu erzeugen. Mit dieser Schwelle sind 151 Gruppen identifiziert, bei denen die größte Gruppe 82  $\mathcal{A}_{v_{\text{max}}}^+$  umfasst, während 75 Gruppen nur 2  $\mathcal{A}_{v_{\text{max}}}^+$  umfassen und somit keinen Hotspot darstellen. Weiterhin sind 465  $\mathcal{A}_{v_{\text{max}}}^+$  aller 1.335  $\mathcal{A}_{v_{\text{max}}}^+$  mehr als  $d_{\text{hspot}}$  von einer anderen  $\mathcal{A}_{v_{\text{max}}}^+$  entfernt und bilden somit keine Gruppe. Anstatt zur Auswahl von Hotspots aus diesen Gruppen alleinig die Anzahl der  $\mathcal{A}_{v_{\text{max}}}^+$  zu betrachten, wird wie in der vorangegangenen makroskopischen Betrachtung zu Objekten erneut die Anzahl der Abweichungen auf die Anzahl der Vorbeifahrten  $V_{\mathcal{O}}$  als normierende Größe bezogen. Es gilt daher wie zuvor zur Berechnung des Gruppenwert  $\mathcal{G}$  als Vergleichsgröße:

$$\mathcal{G}_i = \sum_{j=1}^N \frac{1}{\mathcal{V}(\mathcal{O}_{j,i})} \quad (5-3)$$

Die Verteilung der bestimmten Gruppenwerte ist nachfolgend für alle 151 Gruppen als eCDF in Abb. 5-41 (a) dargestellt. Zur weiteren mikroskopischen Untersuchung werden die 30 Gruppen mit den höchsten  $\mathcal{G}$  als Hotspots ausgewählt. Diese 30 Hotspots entsprechen in der unten links dargestellten eCDF dem mit  $\blacklozenge$  markiertem Bereich und sind in Abb. 5-41 (b) als Balkendiagramm mit ihrem jeweiligen Gruppenwert dargestellt. Im Gegensatz zu den gebildeten Gruppen der  $\mathcal{A}_{\bar{\mathcal{O}}}$  ist der signifikanteste Hotspot der  $\mathcal{A}_{v_{\text{max}}}^+$  (ganz rechts im Balkendiagramm) mit  $\mathcal{G} = 0,43$  deutlich kleiner als 1,0. Es kommt daher für keine Gruppe der  $\mathcal{A}_{v_{\text{max}}}^+$  zu einer Abweichung bei jeder aufgezeichneten Vorbeifahrt der zugehörigen örtlichen Stelle. Auch ist der 30. Hotspot mit  $\mathcal{G} = 0,03$  deutlich kleiner und daher als wenig signifikant zu bewerten. Dennoch könnte es sich um eine Unzulänglichkeit des OuT bezüglich dynamischer Elemente wie bspw. Hindernisse handeln, weshalb auch diese Gruppe mikroskopisch betrachtet wird.



(a) eCDF des normierten Vergleichswertes  $\mathcal{G}$  aller Gruppen.

(b) Ausgewählte Gruppen als Hotspots. Vergleichswert von 30 Gruppen mit den höchsten  $\mathcal{G}$ .

Abbildung 5-41: Normierter Gruppenvergleich basierend auf Anzahl der Abweichungen sowie der Anzahl der Vorbeifahrten.

Die 30 Hotspots inkludieren in Summe 557 Abweichungen, was etwa 42 % der insgesamt 1.335  $\mathcal{A}_{v_{\max}}^+$  entspricht. In nachfolgendem Ausschnitt des Streckennetzes in Abb. 5-42 sind 27 der 30 Hotspots abgebildet. Alle 30 Hotspots treten ausschließlich im urbanen Bereich auf und nicht etwa während Überlandfahrten zwischen den Stadtgebieten. In Kombination mit den geringen Gruppenwerten  $\mathcal{G}$  lässt dies mutmaßen, dass es sich um dynamische Gründe wie Hindernisse oder Zustände von LSA handelt.

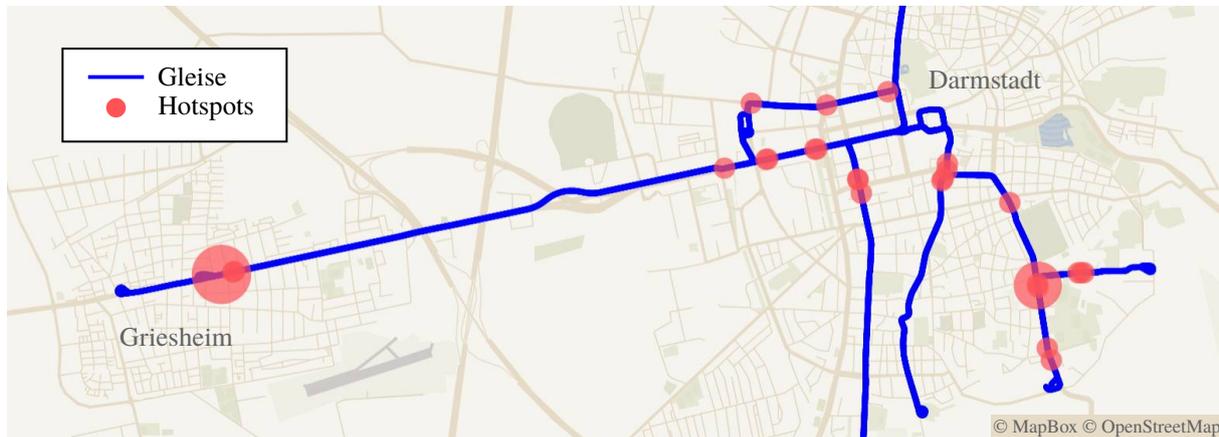


Abbildung 5-42: Kartenausschnitt des Streckennetzes mit 27 der 30  $\mathcal{A}_{v_{\max}}^+$  Hotspots. Die Größe der  $\bullet$  indiziert den zugehörigen Vergleichswert  $\mathcal{G}$ . Eine gesamtheitliche Darstellung aller Hotspots ist in Anhang B.10.

Für die 30 Hotspots sind erneut jeweils 5 zufällige Messreihen als Stellvertreter für die nachfolgende mikroskopische Betrachtung ausgewählt.

### 5.5.2 $\mathcal{A}^+$ Mikroskopische Betrachtung

Die mikroskopische Analyse der Hotspots hat ergeben, dass sich insgesamt 10 Hotspots auf dieselbe auslösende Ursache beziehen. Im weiteren Verlauf dieses Kapitels werden die Ursachen der Abweichungen erläutert. Die Zerteilung einer Ursache in mehrere Hotspots ist durch die Wahl von  $d_{\text{hspot}} = 3$  m begründet, wobei eine Erhöhung dieses Grenzwertes auch zum fälschlichen Zusammenfassen unterschiedlicher Ursachen führen kann. Aus diesem Grund wird im Folgenden von 20 Hotspots ausgegangen, die jeweils einer örtlichen Ursache zugeordnet werden. Außerdem werden wie in den vorherigen Kapiteln zur mikroskopischen Betrachtung verschiedene Einzelfälle, die als Stellvertreter für die jeweilige Ursache stehen, erläutert und kurz eingeordnet. Eine gemeinschaftliche Bewertung erfolgt im nachfolgenden Kapitel zur Teilevaluation der  $\mathcal{A}^+$ .

#### Abweichungen begründet durch reale Objekte

Wie im makroskopischen Teil erläutert, sind in den Messdaten 19  $\mathcal{A}^+$  aufgetreten, bei denen während des Eintretens der Abweichung die Verhaltensplanung zu Objekten aktiv war. Aus der mikroskopischen Einzelbetrachtung geht hervor, dass es sich in sechs Fällen um kritische Szenarien mit Objekten handelt. Wie im Rahmen der Referenzimplementierung in Kapitel 4.4

beschrieben, prüft das umgesetzte OuT aus Gründen der Komplexität lediglich, ob ein Objekt den Fahrschlauch verlässt, jedoch nicht ob dieses in den Fahrschlauch eindringt. In vier dieser kritischen Szenarien handelt es sich um Pkw, die zuvor außerhalb des Fahrschlaches auf einem eigenen Fahrstreifen rechts vor der Straßenbahn fahren und dann unrechtmäßig nach links abbiegen oder zumindest vor die Straßenbahn fahren. Trotz fehlender Prädiktion für Objekte, die in den Fahrschlauch eintreten, hat das OuT mit einer starken Bremsung in etwa zeitgleich mit dem menschlichen Fahrer reagiert. Die  $\mathcal{A}_O^+$  entstehen in allen vier Fällen erst dadurch, dass sich die Pkw durch weiter- oder zurückfahren vor einer Kollision aus dem Fahrschlauch bewegen und das OuT die starke Bremsung abbricht. Der menschliche Fahrer bremst für einen kurzen Augenblick weiter, wonach es aufgrund der einfachen Betrachtung mittels  $\Delta a > a_{\text{krit}}$  zu einer Abweichung kommt.

Zur Verdeutlichung ist nachfolgend in Abb. 5-43 ein solcher beinahe Abbiegeunfall sowohl als Bilderfolge wie auch als Verlauf der Beschleunigungen und des Fahr-Brems-Sollwertgebers dargestellt. Der Pkw zeigt zu Beginn des Szenarios das Abbiegen mit seinen Fahrtrichtungsanzeigern an, woraufhin der menschliche Fahrer der Straßenbahn bereits während des  $\blacklozenge$  markierten Bereichs erstmalig kurz bremst und dann die Straßenbahn rollen lässt. Zu diesem Zeitpunkt plant das OuT noch eine geringe Beschleunigung, um auf die Streckenhöchstgeschwindigkeit zu regeln. Bei etwa 3,6 s der unten dargestellten Zeitachse löst der Fahrer eine Gefahrenbremsung aus und etwa 300 ms später folgt das OuT mit einer starken Bremsung. Aufgrund des Abbaus der Geschwindigkeit der Straßenbahn und der diagonalen Fahrweise des Pkw ist gegen Ende des Szenarios aus Sicht des OuT keine Kollision mehr zu erwarten, weshalb das OuT die Bremsung reduziert und bei etwa 7 s, nachdem der Pkw den Fahrschlauch wieder verlassen hat, erneut plant auf Streckenhöchstgeschwindigkeit zu beschleunigen. Der Fahrer bremst jedoch weiterhin und löst somit eine  $\mathcal{A}_O^+$  aus.

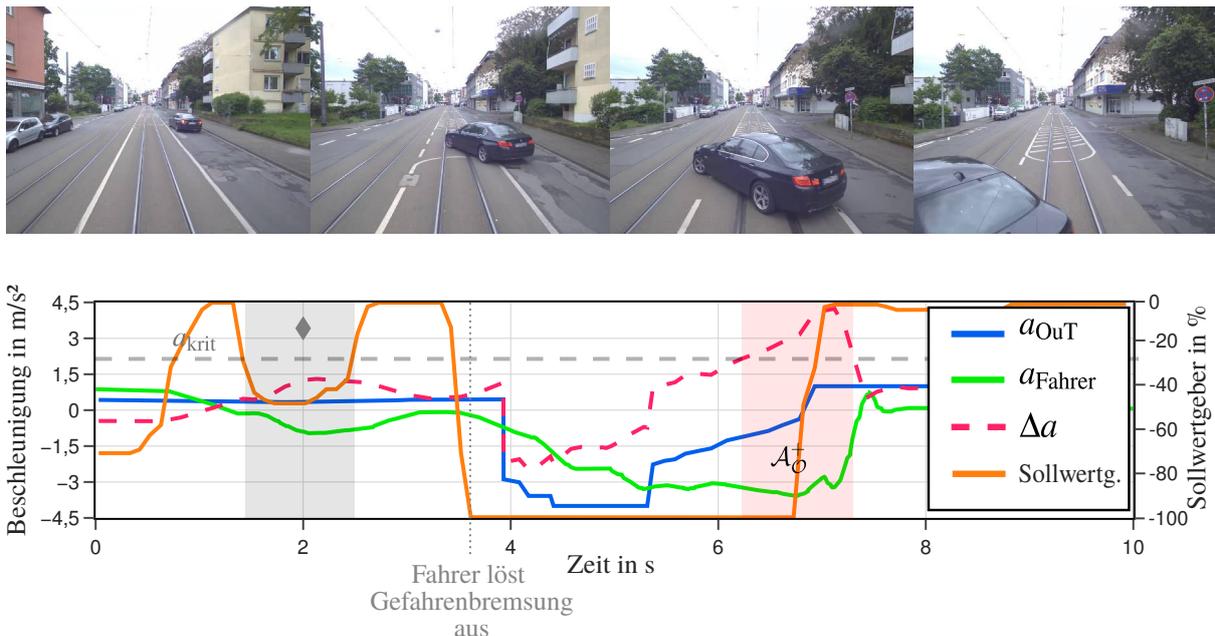


Abbildung 5-43: Beispiel  $\mathcal{A}_O^+$  durch zu lange Fahrerreaktion.

Auch wenn es sich bei dieser  $\mathcal{A}_O^+$  um eine falsch positiv identifizierte Abweichung handelt, ist die Reaktion des OuT aufgrund der fehlenden Prädiktion für Objekte, die in den Fahrschlauch eintreten, als unzureichend zu bewerten. Der menschliche Fahrer scheint sich für das oben gezeigte Beispiel mutmaßlich nicht sicher zu sein, ob der Pkw wirklich abbiegt und bremst zumindest kurzzeitig, sobald der Pkw seine Fahrtrichtungsanzeiger betätigt.

Die anderen drei kritischen Szenarien — darunter bereits das im Rahmen der  $\mathcal{A}_O^-$  in Abb. 5-38 gezeigte Wendemanöver über den besonderen Bahnkörper — sind ähnlich begründet.

Weiterhin ist in **H<sub>+</sub>1** als Ursache für besonders starke Bremsungen des menschlichen Fahrers, während OuT auf die Höchstgeschwindigkeit regelt, eine unzureichende Prädiktion der Automatisierung vermutet. Dazu sind alle  $\mathcal{A}_{v_{\max}}^+$  mikroskopisch ausgewertet, bei denen der Fahrer mit mindestens  $-1,9 \text{ m/s}^2$  verzögert hat. In 11 dieser 35 Fälle sowie in den restlichen 2 Fällen der kritischen  $\mathcal{A}_O^+$  handelt es sich um eine frühe Bremsreaktion des Fahrers durch eine korrekte Antizipation der vorherrschenden Situation. Die genauen Gründe für die starke Bremsung sind vielfältig:

- **Ausfahrten:** Kraftfahrzeuge fahren rückwärts wie vorwärts aus Ausfahrten und übersehen die herannahende Straßenbahn. In allen betrachteten Fällen haben die Kraftfahrzeuge ihr Fehlverhalten bemerkt und durch eine eigene starke Bremsung rechtzeitig vor Betreten des Fahrschlauches angehalten.
- **Linksabbieger:** Kraftfahrzeuge biegen vor der Straßenbahn nach links ab und übersehen dabei wie in Abb. 5-43 oben gezeigtem Beispiel die herannahende Straßenbahn.
- **Vorfahrtsregeln ignoriert:** Kraftfahrzeuge begehen einen Rotlichtverstoß oder gewähren an Kreuzungen der Straßenbahn den Vorrang nicht. Für den menschlichen Fahrer ist die Antizipation des Fehlverhaltens hierdurch vereinfacht, da eindeutig ist, dass der andere Verkehrsteilnehmer stehen müsste.
- **Potenzielle sekundäre Unfallbeteiligung:** Es sind zwei Szenarien identifiziert, bei denen der Fahrer der Straßenbahn bremst, weil er eine Kollision zwischen zwei anderen Verkehrsteilnehmern erwartet. In beiden Fällen ist die Straßenbahn nicht direkt beteiligt, jedoch könnte durch den Aufprall einer der Verkehrsteilnehmer in den Fahrschlauch eintreten.
- **Kreuzende Fußgänger, Radfahrer etc.:** Für alle Bereiche des Straßenbahnnetzes wie Kreuzungen, unabhängige Bahnkörper, Innenstadt etc. sind Gefahrenbremsungen für durch unvorsichtig kreuzende Fußgänger, Radfahrer etc. identifiziert. Als Beispiel sind nachfolgend zwei Szenarien mit kreuzenden Verkehrsteilnehmer in Abb. 5-44 und Abb. 5-45 gezeigt.



Abbildung 5-44: In der Innenstadt befinden sich zwei entgegengerichteten Straßenbahnen auf der linken Seite. Eine Person überquert zwischen diesen fahrenden Straßenbahnen die Gleise und sieht aufgrund der Verdeckung durch das Ende der ersten entgegengerichteten Straßenbahn die herannahende Ego-Straßenbahn nicht. Der menschliche Fahrer der Ego-Straßenbahn löst bereits bei etwa Bild 2 eine Gefahrenbremsung aus, während das OuT erst bei Betreten des Fahrschlauches reagiert.



Abbildung 5-45: Ein Fahrradfahrer fährt über den von einer LSA freigegebenen rechten Teil der Straße und übersieht vor Überquerung des besonderen Bahnkörpers die herannahende Straßenbahn trotz für ihn gelb blinkender Warnsignale. Der menschliche Fahrer der Ego-Straßenbahn erkennt, dass der Fahrradfahrer nicht rechtzeitig anhalten wird und löst bereits bei etwa Bild 2 eine Gefahrenbremsung aus. Das OuT reagiert entsprechend der Verhaltensplanung erst bei Betreten des Fahrschlauches.

Für die oben gezeigten zwei Beispiele zur Gefahrenbremsung aufgrund kreuzender Verkehrsteilnehmer ist neben der Verhaltensvorhersage auch die sensorische Erfassung eine Herausforderung: Die kreuzende Person ist aufgrund der Verdeckung spät zu detektieren und bewegt sich dabei nicht radial zur Bahn, weshalb sowohl für Radar wie auch zukünftige FMCW-basierte Lidare insbesondere die Bestimmung der Geschwindigkeit und damit ein Indikator der Absicht zu kreuzen, wegen fehlendem Dopplereffekt nur schwer zu detektieren sein wird. Der kreuzende Fahrradfahrer bewegt sich ebenfalls nur wenig radial zur Bahn, weshalb auch hier der Dopplereffekt kaum auftritt. Darüber hinaus wird der Fahrradfahrer sowohl von Verkehrsschildern wie auch anderen Pkw teil- oder vollständig verdeckt.

Die oben aufgezählten Gründe sowie gezeigten Beispiele spiegeln nur einen Teil der möglichen Szenarien wider und bestehen neben dem gezeigten vermeintlich einfacheren Erkennen der Absicht zum Kreuzen teilweise auch aus komplexeren Zusammenhängen. Hinzu kommt, dass in aufgezeichneten Daten mit einer Gesamtstrecke von 12.767 m auch nicht alle denkbaren Szenarien enthalten sind. Die menschliche Erkennungsleistung ist bei solchen Szenarien nicht nur aufgrund der sensorischen Erfassung, sondern auch aufgrund der Erfahrung und Antizipation der Absicht des anderen Verkehrsteilnehmers deutlich überlegen. Dabei handelt es sich nicht um eine einzigartige Herausforderung der Automatisierung von Straßenbahnen, da die Vorhersage von Fehlverhalten anderer Verkehrsteilnehmer auch für automatisierte Kraftfahrzeuge eine besondere

Herausforderung darstellt.<sup>199, 200</sup> Aufgrund des für die Straßenbahn reservierten besonderen und unabhängigen Bahnkörpers sowie dem Einsatz in der Innenstadt und an Haltestellen mit vielen Fahrgästen unterscheiden sich jedoch die Anforderungen an die zu lösende Prädiktion.

Hypothese  $H_+1$ , welche aufgrund der makroskopisch stärkeren Bremsungen des Fahrers eine unzureichende Prädiktion der Automatisierung vermutet, ist durch Widerlegung der zugehörigen Nullhypothese als bestätigt zu bewerten. Die mehrheitliche Ursache für starke Bremsungen des Fahrers ist jedoch auf LSA zurückzuführen, welche im weiteren Verlauf dieses Kapitels näher betrachtet werden.

Neben der unzureichenden Prädiktion für kritische Szenarien sind jedoch in der gesamtheitlichen mikroskopischen Betrachtung mehrere Szenarien identifiziert, die nicht unmittelbar eine erhöhte Kritikalität aufweisen, bei denen der Fahrer aber dennoch besonders früh reagiert hat. Als Beispiele sind dabei zu nennen:

- Pkw, welche die Gleise beim seitlich rückwärts einparken blockieren.
- Langsame Fahrt an Engstellen durch parkende Fahrzeuge.
- Kooperatives Verhalten gegenüber Kraftfahrzeugen, z. B. an Halt zeigenden LSA andere Verkehrsteilnehmer vor der Straßenbahn einscheren lassen etc.

Zusammenfassend lässt sich einordnen, dass der Fahrer in verschiedenen Szenarien besonders früh oder kooperativ reagiert hat, weshalb die zuvor als Vermutung hierzu aufgestellte Hypothese  $H_+3$  als verifiziert bewertet wird. Dabei handelt es sich weder um eine unmittelbare sicherheitsrelevante Unzulänglichkeit noch um straßenbahnspezifische Herausforderungen, die nicht auch für die Automatisierung von Kraftfahrzeugen gültig ist. Da in einigen dieser Szenarien jedoch mehrere Verhalten als korrekt angesehen werden können, ohne dass diese unterschiedlichen Verhalten die Kritikalität erhöhen, erschwert dies auch bei komplexeren Vergleichsmetriken als  $\Delta a > a_{\text{krit}}$  die Anwendung bzw. Auswertung von *Silent Testing*.

### Abweichungen begründet durch LSA zur Vorfahrt

Bedingt durch die Auswahl der Stellvertreter und Hotspots sind in Summe 195 Messreihen mit  $\mathcal{A}_{v_{\text{max}}}^+$  mikroskopisch ausgewertet. Dabei ist mit 101  $\mathcal{A}_{v_{\text{max}}}^+$  die absolute Mehrheit auf Abweichungen durch vorfahrtsregelnde LSA zurückzuführen. Auch sind 14 der 20 Hotspots auf LSA zurückzuführen. Die Ursachen für die Abweichungen sind auch für die jeweiligen Hotspots vielfältig und werden im Folgenden erläutert.

199 Wiederer, J. et al.: Anomaly Detection (2022).

200 Wang, C. et al.: "Watch out!" (2020).

## Verhalten bei F 4

Eine wesentliche Ursache ist der Wechsel von einer freigegebenen Fahrt mit F 1–3 oder F 5 zu einem F 4, welches einen zu erwartenden Halt anzeigt. Entsprechend der umgesetzten Referenzimplementierung wird erst bei einem detektierten F 0 verzögert. Für Szenarien, in denen die Straßenbahn noch weiter von der LSA entfernt ist, reicht diese Verhaltensplanung jedoch nicht aus und ein Anhalten sollte bereits bei F 4 eingeleitet werden. Dennoch sollte auch nicht für F 4 gehalten werden, wenn die Vorbeifahrt aufgrund eines geringen Abstandes und der eigenen Geschwindigkeit noch vor dem Wechsel zu F 0 möglich ist und somit eine unnötig starke Bremsung vermieden werden kann. In diesem Fall hat *Silent Testing* keine besondere Herausforderung der Automatisierung, sondern eine Unzulänglichkeit der Referenzimplementierung aufgezeigt.

Gleichzeitig stellt F 4 auch bei Beachtung mit der Referenzimplementierung die Anwendung von *Silent Testing* mit  $\Delta a > a_{\text{krit}}$  als Vergleichsmetrik vor eine Herausforderung. So sind in den 35 Messreihen zu stärkeren Bremsungen 13 Fälle enthalten, bei denen der Fahrer für F 4 bremst. Selbst wenn ein ideales Entscheidungskriterium zum Anhalten oder zügigem Weiterfahren für das OuT analytisch existiert, ist die Anwendung von *Silent Testing* aufgrund der Varianz des menschlichen Verhaltens erschwert. Ohne eine *Ground Truth* zum Signalzustand würden auch Filter, die bspw. retrospektiv betrachten, ob danach ein F 0 gezeigt worden ist, auf die Validität der kamerabasierten Detektion angewiesen sein.

So zeigt zur Verdeutlichung nachfolgende Abb. 5-46 ein Szenario, in dem der Fahrer bei guten Bedingungen mit einer maximalen Betriebsbremse (ohne Gefahrenbremsung) mit bis zu  $-3,4 \text{ m/s}^2$  verzögert und die Front der Bahn dennoch erst kurz hinter der LSA zum Stehen kommt. Das Signal F 4 ist erstmalig bei etwa 60 m Entfernung zu erkennen, während die Straßenbahn mit etwa 60 km/h fährt. Zu diesem Zeitpunkt entspräche dies einer durchschnittlichen Verzögerung von  $-2,3 \text{ m/s}^2$ , jedoch benötigt auch der menschliche Fahrer etwa 1 s Reaktionszeit und bremst auch nicht zu Beginn mit einer maximalen Betriebsbremse. Wäre der Fahrer unbeschleunigt weiter gefahren, hätte die Front der Bahn die LSA um etwa 7 m passiert, während noch F 4 angezeigt wurde.



Abbildung 5-46: Extrembeispiel für eine fehlende Reaktion des OuT bei F4. Links ist das F 4 Signal zu erkennen, welches in der mittigen Abbildung auf F 0 wechselt. Die Bahn kommt erst nach dem Signal zum Stehen.

## Zurollen auf LSA

Etwa 60 aller 248 mikroskopisch betrachteten  $\mathcal{A}_{v_{\max}}^+$  sind auf ein frühes Bremsen und langsames Zurollen auf eine Halt zeigende LSA zurückzuführen. Dabei ist dies nur eine ungefähre Angabe, da der Übergang zu einer früheren Erkennungs- und Reaktionsleistung fließend ist. So sind 41 weitere Fälle identifiziert, bei denen der Fahrer für F0 bremsst, während das OuT dieses aufgrund der Entfernung noch nicht detektiert hat. Die Mehrheit dieser Fälle treten bei Strecken mit einer Höchstgeschwindigkeit von 70 km/h auf. Sie bilden somit das Gegenstück zu den in Kapitel 5.1.2 analysierten  $\mathcal{A}_{\text{LSA}}^-$ , bei denen das OuT für nicht detektierte Signalzustände bei größeren Abständen vorsorglich bremsst. Diese 41  $\mathcal{A}_{v_{\max}}^+$  bestärken daher in Kapitel 5.1.2 genannten Probleme der kamerabasierten Detektion der LSA. Das menschliche Zurollen auf LSA könnte auch als komfortable oder energieeffiziente Fahrweise betrachtet werden, da im Gegensatz zum Individualverkehr die Signalanforderung nicht über eine Induktionsschleife oder Kamera unmittelbar vor der LSA, sondern per Funk erfolgt. Dieses menschliche Verhalten unterliegt jedoch einer signifikanten Streuung. Teilweise rollt der Fahrer gar nicht und bremsst erst kurz vor dem Haltzeichen, während in anderen Fällen bereits bei niedrigen Geschwindigkeiten und vergleichsweise großen Abständen zur LSA gebremst wird. Letzterer Fall ist nachfolgend als Bildfolge und Beschleunigungsverlauf in Abb. 5-47 gezeigt. Der Fahrer bremsst bereits bei etwa 95 m Entfernung, wobei die Straßenbahn zu diesem Zeitpunkt bereits nur eine Geschwindigkeit von 25 km/h aufweist. Aufgrund der frühen und geringen Verzögerung des Fahrers sowie der mehrfach erwähnten Limitierung der Verhaltensplanung die Höchstgeschwindigkeit mit maximal  $+1 \text{ m/s}^2$  einzuregeln,<sup>201</sup> tritt erst nach etwa 15 s nach Bremsbeginn eine kurze  $\mathcal{A}_{v_{\max}}^+$  auf.

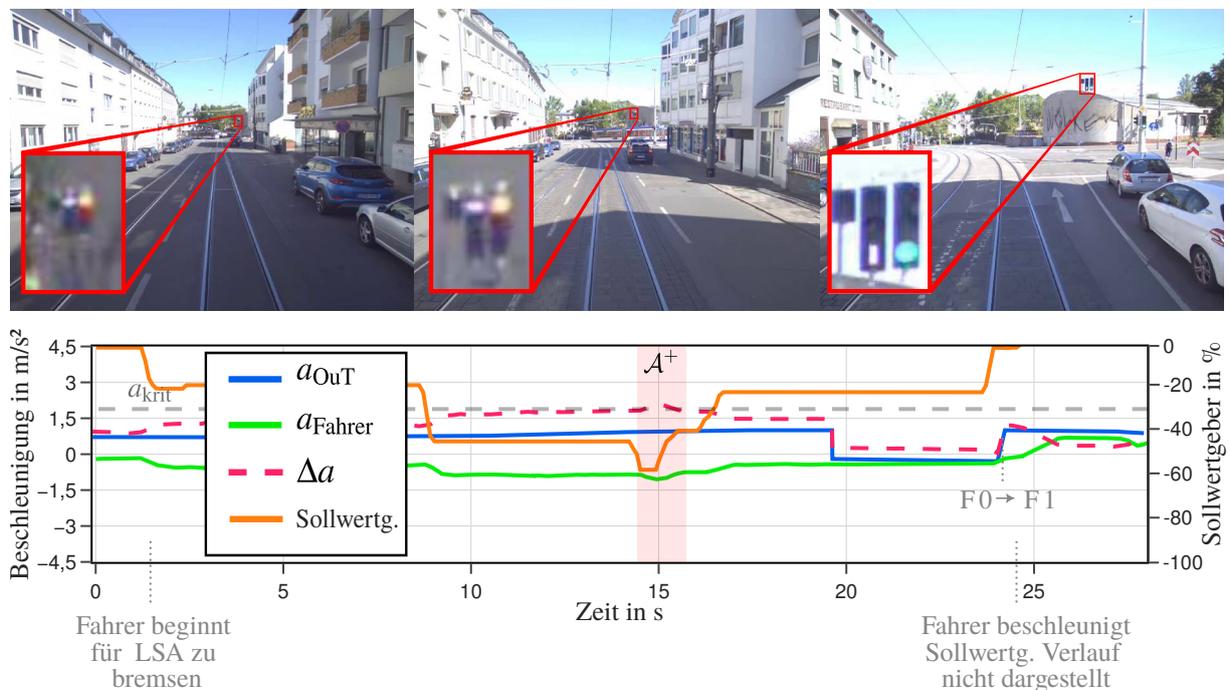


Abbildung 5-47: Beispiel  $\mathcal{A}_{v_{\max}}^+$  durch Zurollen auf LSA.

201 Siehe Kapitel 4.4.10.

Das Zurollen auf die LSA ist keine spezifische Herausforderung der Automatisierung von Straßenbahnen. Aufgrund der Vielfältigkeit des korrekten Verhaltens und der Möglichkeit des exzessiven Rollens aufgrund der funkbasierten Signalanforderung handelt es sich jedoch um Herausforderungen bei der Anwendung von *Silent Testing*. In ähnlicher Weise wie für die oben diskutierten Abweichungen durch F4 gilt auch hier, dass nachträgliches Filtern ohne *Ground Truth* zum Signalzustand erschwert ist. Neben der Abweichung durch frühes Bremsen sind auch Messreihen identifiziert, bei denen der menschliche Fahrer leicht bremsend auf eine LSA zurollt und weiterhin für mehrere Sekunden brems, obwohl die LSA bereits auf ein Fahrt freigebendes Signal gewechselt hat. Diese Fälle bilden somit das Gegenstück zu den im Rahmen der mikroskopischen  $\mathcal{A}_{\text{LSA}}^-$  Betrachtung identifizierten Fällen, in denen der Fahrer das Umschalten von F0 auf ein Fahrt freigebendes Signal erwartet und bereits losfährt. Diese unterschiedlichen Reaktionszeiten und deren Bedeutung sind bereits zuvor in Kapitel 5.1.2 diskutiert. Sowohl Teile der Abweichungen bezüglich des Verhaltens bei F4, dem langsamen Zurollen auf LSA wie auch beim Umschalten von F0 auf ein Fahrt freigebendes Signal sind auf eine Varianz des menschlichen Verhaltens zurückzuführen. Hauptsächlich ist diese Schwierigkeit für *Silent Testing* auf die vergleichsweise einfache Vergleichsmetrik  $\Delta a > a_{\text{krit}}$  zurückzuführen. Die hierzu gebildete Hypothese  $\mathbf{H}_+2$  ist als verifiziert zu bewerten.

## Falscher Signalzustand

Neben dem unzureichend vorausschauenden Verhalten bei F4 wurde bezüglich LSA nur eine einzelne Messreihe mikroskopisch identifiziert, bei der sich das OuT eindeutig sicherheitsrelevant falsch verhalten hätte. So ist nachfolgend in Abb. 5-48 die Annäherung an eine LSA gezeigt, die in der Realität mit F0 einen Halt signalisiert.

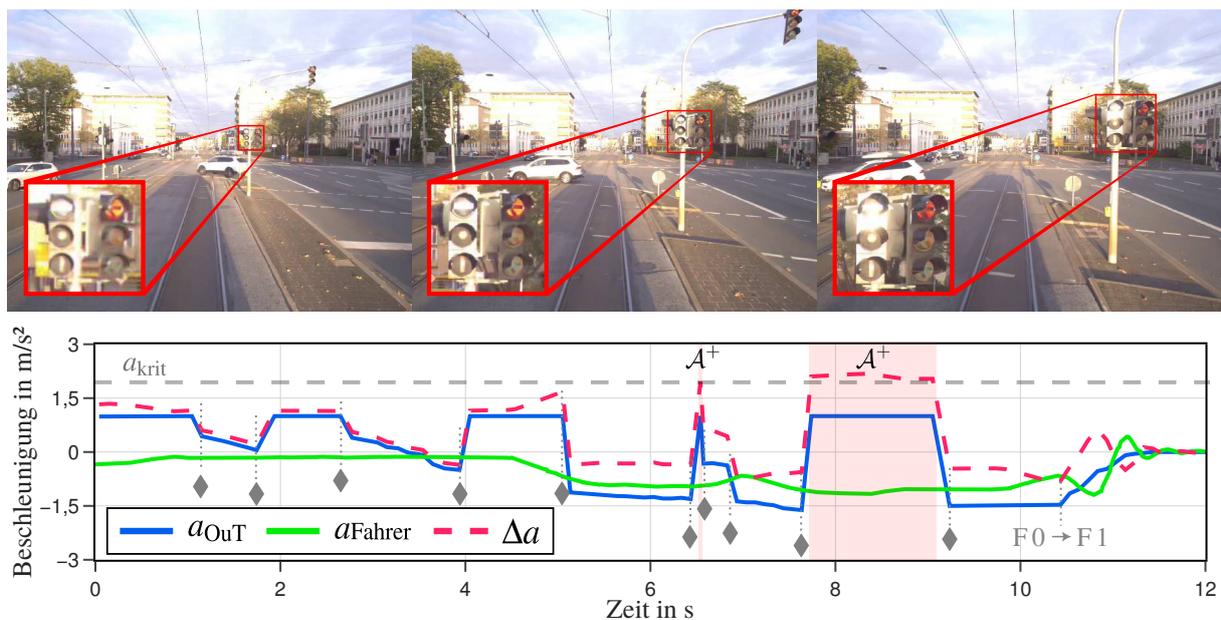


Abbildung 5-48: Aufgrund von Sonneneinstrahlung wird von der kamerabasierten Erfassung kurzzeitig F1 statt F0 detektiert.

Aufgrund der Sonneneinstrahlung ist das Signal jedoch nicht zu erkennen, das OuT erkennt stattdessen mehrfach für einen kurzen Zeitraum F 1. Die entsprechenden Wechsel der Detektionen sind mit  $\blacklozenge$  im geplanten Beschleunigungsverlauf  $a_{\text{OuT}}$  der obigen Abbildung markiert. Aufgrund des frühen Bremsens des menschlichen Fahrers und der Beschränkung<sup>201</sup> der Verhaltensplanung zur Regelung der Höchstgeschwindigkeit auf  $+1 \text{ m/s}^2$  wird die Schwelle  $a_{\text{krit}}$  zur Identifikation von Abweichungen nur zwei Mal gering überschritten. Die Identifikation solcher Unzulänglichkeiten ist für *Silent Testing* mit der genutzten Vergleichsmetrik erschwert. Aufgrund der fehlenden Farbe und der kleineren leuchtenden Fläche lässt sich zumindest vermuten, dass Sonneneinstrahlung für LSA des ÖPNV grundsätzlich eine größere Herausforderung darstellt als für LSA des Individualverkehrs, jedoch ist dies nur ein aufgezeigter Fall und es bedarf hier weiterer Untersuchungen. Grundsätzlich ist das Problem der Sonneneinstrahlung aber auch für LSA des Individualverkehrs bekannt.

### Fehlende Erfassung der Weichen

Wie im Rahmen der Konkretisierung der Referenzarchitektur in Kapitel 4.3 aufgezeigt, ist die Erfassung von LSA, welche die Lage von Weichen anzeigen, nicht Teil dieser Arbeit. Dies ist mit dem Aufwand des Annotierens von Trainingsdaten sowie ähnlich zu erwartenden Herausforderungen wie für vorfahrtsregelnde LSA begründet. Durch die fehlende Erfassung dieser Weichen-Signale erfolgt jedoch auch keine Verhaltensplanung. So sind drei der 20 Hotspots auf die fehlende Erfassung von Weichenlagen zurückzuführen. An allen mikroskopisch betrachteten Messreihen zu diesen drei Hotspots nähert sich die Straßenbahn der Weiche, welche in die falsche Richtung gelegt ist. Der menschliche Fahrer bremst vergleichsweise leicht, um der Weiche genug Zeit zu geben, auf den Stellbefehl zu reagieren und sich in die richtige Richtung zu legen. Da das OuT aus den oben genannten Gründen das Verhalten für noch nicht korrekt gelegte Weichen nicht anpasst, kommt es zu einer  $\mathcal{A}_{\text{vmax}}^+$ . Abgesehen von den in dieser Arbeit beschriebenen Herausforderungen der kamerabasierten Detektion von Signalen ist dies jedoch keine spezifische Herausforderung der Automatisierung von Straßenbahnen, sondern eine Unzulänglichkeit der Referenzimplementierung.

### Abweichungen durch ÖPNV Betrieb

Neben den Abweichungen, welche durch reale Hindernisse, LSA oder Weichen begründet sind, sind zusätzlich vereinzelt Abweichungen auf den Einsatz innerhalb eines ÖPNV Betriebs zurückzuführen. So sind drei der 20 gebildeten Hotspots durch eine Belegung von Haltestellen durch andere Straßenbahnen oder Busse bedingt. Die potenzielle Einfahrt der Ego-Straßenbahn in eine bereits belegte und für zwei Fahrzeuge unzureichende Haltestelle könnte sowohl eine Gefährdung der Fahrgäste verursachen, die sich außerhalb der Haltestelle im weiteren Verkehrsraum aufhalten als auch bestimmte Punkte im Individualverkehr wie Einmündungen und Kreuzungen beeinträchtigen. Eine derartige Situation würde nicht nur Sicherheitsbedenken hervorrufen, sondern auch potenzielle Beeinträchtigungen des fließenden Verkehrs mit sich bringen. Ein komplexeres

Beispiel hierzu ist nachfolgend in Abb. 5-49 (a) links gezeigt. Die Ego-Straßenbahn wartet trotz F 1 an einer LSA, da auf der anderen Straßenseite die Haltestelle in Fahrtrichtung belegt ist.

Vereinzelte sind im Rahmen der mikroskopischen Betrachtung zu geringen Bremsungen des Fahrers auch Abweichungen durch Arbeiten im Gleisbereich identifiziert. Dabei handelte es sich neben Mäharbeiten auch um Arbeiten an der Oberleitung oder dem Gleis selbst. Für gewöhnlich werden die menschlichen Fahrer über diese Arbeiten von der Betriebsleitstelle informiert. Auch ohne zusätzliche Beschilderung reduzieren die menschlichen Fahrer ihre Geschwindigkeit im Gefahrenbereich. So bremst der Fahrer in dem nachfolgend rechts in Abb. 5-49 (b) gezeigten Beispiel kurzzeitig von der erlaubten Streckenhöchstgeschwindigkeit von 40 km/h auf bis zu 8 km/h ab, da sich Arbeiter im Gleisbereich befinden. Das OuT reagiert entsprechend der Verhaltensplanung nicht, da kein Arbeiter innerhalb des Fahrschlauches ist.



(a) Aufgrund der belegten Haltestelle durch eine vorausfahrende Straßenbahn wartet die Ego-Straßenbahn trotz F 1 an einer LSA.



(b) Der menschliche Fahrer bremst aufgrund von Arbeiten am Gleiskörper von erlaubten 40 km/h auf bis zu 8 km/h ab.

Abbildung 5-49: Abweichungen durch belegte Haltestelle und Gleisarbeiten.

Beide gezeigten Beispiele sind nicht im Rahmen der Verhaltensanforderungen und damit der Referenzarchitektur berücksichtigt. Dementsprechend ist mit der Anwendung von *Silent Testing* nicht nur eine Herausforderung der Automatisierung von Straßenbahnen im Rahmen der technischen Umsetzung, sondern auch straßenbahnspezifische bzw. ÖPNV-spezifische neuartige Verhaltensanforderungen aufgezeigt.

### 5.5.3 $\mathcal{A}^+$ Teilevaluation

Im folgenden Teilabschnitt werden die makroskopisch wie mikroskopisch untersuchten  $\mathcal{A}^+$  bezüglich der Automatisierung von Straßenbahnen und der Anwendung von *Silent Testing* eingeordnet.

## Intentionserkennung der Objekte im Kontext der $\mathcal{A}^+$

Im Rahmen der in dieser Arbeit umgesetzten Referenzimplementierung ist keine Vorhersage für das zukünftige Eindringen anderer Verkehrsteilnehmer in den Fahrschlauch berücksichtigt. Die hier als Automatisierungssystem umgesetzte Intentionserkennung beschränkt sich auf die in Kapitel 4 aufgezeigte Schätzung, ob ein bereits im Fahrschlauch befindliches potenzielles Hindernis nur kreuzt und den Fahrschlauch verlassen haben wird, bevor die Straßenbahn an dieser Stelle ankommt.

Es sind mikroskopisch mehrere Szenarien identifiziert und im vorherigen Kapitel Beispiele aufgezeigt, bei denen der menschliche Fahrer ein mögliches Eindringen in den Fahrschlauch erahnt. Insbesondere in Gefahrensituationen, die in der Betrachtung dieser Arbeit alle durch andere Verkehrsteilnehmer verschuldet sind, hat der menschliche Fahrer durch eine Reaktion vor Eindringen in den Fahrschlauch angemessen reagiert. Ein potenzielles Automatisierungssystem wäre in diesen Szenarien zwar nicht Unfallverursacher, hätte jedoch die Schwere oder den Unfall selbst, wie auch der menschliche Fahrer, verhindern können. Dies wirft auch die Frage nach dem zu erbringenden Sicherheitsnachweis zur Validierung solcher Automatisierungen und dem damit verbundenen gesellschaftlich akzeptierten Risiko auf. Es scheint jedoch evident, dass auch eine Automatisierung von Straßenbahnen zumindest einen großen Teil solcher Unfälle verhindern können muss. Die Intentionserkennung ist zwar auch grundsätzlich im Kraftfahrzeugbereich eine Herausforderung, jedoch ergeben sich durch die verschiedenen Einsatzgebiete sowie große Nähe zu Passanten und anderen ungeschützten Verkehrsteilnehmern neue Randbedingung an die technische Umsetzung.

Insbesondere reichen einfache physikalische Bewegungsmodelle für andere Verkehrsteilnehmer nicht aus. Es sind mehrere Szenarien aufgezeigt, bei denen die Reaktion des menschlichen Straßenbahnfahrers nicht aus einer eindeutig extrapolierbaren Bewegung hervorgeht, sondern der Fahrer die Intention der anderen Verkehrsteilnehmer antizipiert. Neben kritischen Szenarien, in denen der Fahrer stark bremst oder sogar eine Gefahrenbremsung auslöst, sind auch Szenarien identifiziert, bei denen der Fahrer besonders früh und kooperativ reagiert. Auch dies ist keine ausschließlich für Straßenbahn gültige Herausforderung des automatisierten Fahrens, jedoch erneut mit eigenen Randbedingungen. So kann bspw. an einem seitlich einparkenden Pkw aufgrund der Spurbindung nicht vorbeigefahren werden, sollte dieser in den Fahrschlauch ragen.

## Lichtsignalanlagen im Kontext der $\mathcal{A}^+$

Wie zuvor in der mikroskopischen Analyse aufgezeigt, ist die Mehrheit der  $\mathcal{A}_{v_{\max}}^+$  auf Abweichungen durch LSA zurückzuführen. Dabei ist die Mehrheit durch die Varianz des menschlichen Verhaltens begründet, was im nachfolgenden Teilabschnitt zu *Silent Testing* näher betrachtet wird. Wie bereits bei den  $\mathcal{A}_{LSA}^-$  aufgezeigt, ist die genutzte Auflösung im Verhältnis zum FoV der Kameras nicht ausreichend und die Detektion von LSA ist insbesondere bei größeren Entfernungen erschwert. Neben der unzureichenden Reichweite ist ein einzelner Fehler des maschinell

gelernten Detektors identifiziert, der besonders kritisch bezüglich der Sicherheit wiegt. Die durch Sonnenlicht verursachte Fehldetektion von F 1 statt F 0 ist zwar nur ein einzelner Fall, zeigt jedoch die Herausforderung der kamerabasierten Detektion von LSA auf.

Wie bereits in der Evaluation der  $\mathcal{A}_{\text{LSA}}^-$  in Kapitel 5.1.3 aufgezeigt, ist die Detektion von LSA jedoch nicht nur eine Herausforderung der Automatisierung von Straßenbahnen, sondern erschwert auch die Automatisierung von Kraftfahrzeugen. Die im Rahmen dieser vorangegangenen Evaluation angeführten Argumente und Motivatoren für eine tiefere technische wie wirtschaftliche Prüfung von V2I Kommunikation sind in Anbetracht der aufgezeigten  $\mathcal{A}^+$  zu bekräftigen.

### **Silent Testing im Kontext der $\mathcal{A}^+$**

Die Anwendung von *Silent Testing* hat eine große Anzahl an Abweichungen bei F 4 anzeigenden LSA aufgezeigt, da das OuT an diesen nicht anhält. In ähnlicher Weise ist auch unzureichendes Verhalten an Weichen aufgezeigt, die sich noch nicht in der richtigen Lage befinden. Einerseits waren beide Unzulänglichkeiten bereits bekannt, da sie zuvor in Kapitel 4 aus Gründen der Komplexität nicht berücksichtigt sind. Andererseits sind beide empirisch erneut identifiziert. Damit ist wie bereits zuvor für andere Themenfelder die Anwendung von *Silent Testing* nicht nur zur Identifikation von Herausforderungen der Automatisierung von Straßenbahnen, sondern auch zur Identifikation von Unzulänglichkeiten eines OuT aufgezeigt. Beide Unzulänglichkeiten sind jedoch nicht spezifisch für Straßenbahnen und grundsätzlich als Entwicklungsaufgabe lösbar.

Es zeigt sich jedoch, dass der menschliche Fahrer eine große Varianz des Verhaltens an LSA aufweist. Insbesondere das Zurollen auf LSA ist eine Herausforderung der Anwendung von *Silent Testing*, da auch bei aufwendigeren Vergleichsmetriken als  $\Delta a > a_{\text{krit}}$  nicht ausgeschlossen werden kann, ob ein Fahrer nur auf eine LSA zurollt oder für ein noch nicht kritisches und von der Automatisierung nicht erkanntes Hindernis bremst. Dies gilt in ähnlichem Maße für die Verhaltensplanung für ein angezeigtes F 4, die Reaktionszeiten beim Wechsel von F 0 auf ein Fahrt freigebendes Signal und anders herum. Diese normale Varianz des menschlichen Verhaltens ist daher als grundsätzliche Schwäche der Methodik um *Silent Testing* zu bewerten.

Aufgrund dieser Schwäche sind eine Vielzahl an  $\mathcal{A}^+$  nicht mikroskopisch untersucht. Weitere Herausforderungen oder Unzulänglichkeiten könnten somit unentdeckt geblieben sein. Insbesondere da im Gegensatz zu den  $\mathcal{A}^-$  der übergeordnete Grund für das Auslösen der  $\mathcal{A}^+$  im Rahmen der Auswertung nicht bekannt ist, ist die Anwendung weiterer Filter prinzipbedingt erschwert. So zeigt bspw., dass die Mehrheit der 19  $\mathcal{A}^+$  bei aktiver Verhaltensplanung zu Objekten durch das menschliche Verhalten an LSA verursacht sind. Die Verhaltensplanung zu Objekten ist in diesen Fällen nur aktiv, da an den LSA auch andere Verkehrsteilnehmer warten und für diese noch vor der LSA anzuhalten ist. Der menschliche Fahrer bremst jedoch nicht für die anderen Verkehrsteilnehmer, sondern rollt in erster Linie langsam auf die LSA zu.

Neben diesen Abweichungen mit geringer Kritikalität bezüglich eines Unfalls sind auch  $\mathcal{A}^+$  identifiziert, bei denen der Fahrer die Intention des anderen Verkehrsteilnehmers antizipiert und entsprechend reagiert. Die Anwendung von *Silent Testing* hat hierbei die Schwächen der umgesetzten Referenzimplementierung aufgezeigt, jedoch auch die Herausforderung der Intentionserkennung von anderen Verkehrsteilnehmern im Bereich der Straßenbahn.

Aufgrund des geringen Auftretens von Szenarien mit real erhöhter Kritikalität sind insbesondere auch fälschlich identifizierte  $\mathcal{A}^+$  zu vertreten, sollten sie wie oben aufgezeigt entstehen, weil der menschlichen Fahrer kurzzeitig länger bremst als absolut notwendig. Einerseits sind solche Abweichungen aufgrund der geringen Anzahl einfach manuell auszusortieren. Andererseits ist aus Sicht des Funktionsentwicklers die mikroskopische Evaluation von Realdaten auch bei korrektem Verhalten für weitere Verbesserungen von Wert.

## 6 Fazit und Ausblick

In diesem Kapitel erfolgt die Zusammenfassung der Ergebnisse der vorliegenden Forschungsarbeit zur Identifikation von Herausforderungen und Plausibilisierung neuer Ansätze zur Automatisierung von Straßenbahnen. Abschließend wird ein Ausblick auf mögliche fortsetzende Forschungsansätze und offene Fragen gegeben.

### 6.1 Fazit

Zu Beginn dieser Arbeit ist die Motivation zur Automatisierung von Straßenbahnen aufgezeigt. Dabei handelt es sich um ein noch junges Forschungs- wie auch Entwicklungsfeld mit vielen offenen Fragen bezüglich der technischen Umsetzung der zu automatisierenden Fahraufgabe. Zwar ist es offensichtlich, möglichst viele Lösungen aus anderen Domänen wie dem Kraftfahrzeugbereich zu transferieren, andererseits ergeben sich durch Besonderheiten der Straßenbahn neue Herausforderungen. Damit diese Herausforderungen zielgerichtet gelöst werden können, ist es notwendig, diese zunächst zu identifizieren. Gleichzeitig ergeben sich durch die neuen Randbedingungen der Straßenbahn auch neue technische Möglichkeiten, welche das Potenzial haben, die komplexe Automatisierungsaufgabe innerhalb eines Teilbereichs zu vereinfachen. Sowohl die Herausforderungen wie auch die neuen potenziellen Möglichkeiten stehen jedoch in einem engen Zusammenhang mit der Komplexität der realen Welt. Einerseits ergeben sich erst aus der Realität Herausforderungen, die in einer rein theoretischen Betrachtung schlichtweg übersehen würden, andererseits sind neue potenzielle Möglichkeiten auch hinsichtlich ihrer Anwendbarkeit in der realen Welt zu bewerten.

Aus diesem Grund ist eine Methode basierend auf dem weit gefassten Ansatz *Silent Testing* abgeleitet. Diese Forschungsarbeit markiert dabei nicht nur die erstmalige Anwendung von *Silent Testing* auf Straßenbahnen, sondern beinhaltet auch die (soweit dem Autor bekannt) erstmalige Veröffentlichung von Erfahrungen von *Silent Testing* im urbanen Umfeld für automatisierte Fahrzeuge im Allgemeinen. Da *Silent Testing* auf einer passiven Erprobung in der realen Welt beruht, ist für die Anwendung ein Automatisierungssystem für Straßenbahnen erforderlich. In Anbetracht dessen, dass zu Beginn dieses Forschungsvorhabens weder ein derartiges System zur Anwendung von *Silent Testing* zur Verfügung steht, noch der Umfang der Automatisierung in der Literatur diskutiert ist, sind im Rahmen dieser Forschungsarbeit erstmalig Verhaltensanforderungen für eine automatisierte Straßenbahn abgeleitet. Diese sind als systematisch abgeleiteten ersten Vorschlag zum Funktionsumfang und Verhalten einer automatisierten Straßenbahn zu bewerten. Basierend auf diesen Verhaltensanforderungen ist eine allgemeingültige sowie eine

von technischen Lösungen abhängige konkrete Referenzarchitektur entworfen. Mit den abgeleiteten Verhaltensanforderungen sowie der Referenzarchitektur ist die zu Beginn dieser Arbeit zuletzt aufgestellte Forschungsfrage FF.4 nach dem Funktionsumfang einer automatisierten Straßenbahn jedoch nur zum größten Teil beantwortet. Die Anwendung von *Silent Testing* hat mithilfe der praktischen Untersuchung weitere Anforderungen wie eine Überprüfung von bereits belegten Haltestellen aufgezeigt. Insbesondere ist es denkbar, dass nach Bewältigung der hier aufgezeigten Herausforderungen und Unzulänglichkeiten im Rahmen einer erneuten Anwendung von *Silent Testing* weitere Anforderungen identifiziert werden. Forschungsfrage FF.4 gilt somit als im Wesentlichen jedoch nicht abschließend beantwortet.

**FF.4**

Welchen Funktionsumfang bezüglich der Fahraufgabe muss eine Automatisierung von Straßenbahnen aufweisen?

Die konkretisierte Referenzarchitektur ist in Form einer Referenzimplementierung umgesetzt und dient in Form eines OuT als Grundlage für die Anwendung von *Silent Testing*. Als Teil der konkretisierten Architektur und somit auch der Implementierung sind zusätzlich neuartige Ansätze als Möglichkeiten zur Vereinfachung der Automatisierungsaufgabe erdacht und integriert. Darunter zählen aufgrund des mit Kraftfahrzeugen und Vollbahnen verglichenen kleinen Einsatzgebietes allem voran die starke Stützung auf Kartendaten zum Abruf des Gleisverlaufs, der Höchstgeschwindigkeit oder die Erzeugung von ROI basierend auf vermessener Infrastruktur sowie einer GNSS- und odometriebasierten Lokalisierung. Besonders für die Bestimmung der Fahrzeugorientierung als Teil der Lokalisierungsaufgabe ist die Zwangskinetik durch Fahrzeug und Gleis als Möglichkeit zur Vereinfachung genutzt. Die a-priori bestimmte Orientierung ist dabei wie andere Informationen in der Karte hinterlegt und wird basierend auf der Position abgerufen. Im Rahmen der praktischen Untersuchung und Anwendung von *Silent Testing* sind keine Abweichungen identifiziert, welche sich auf diese umgesetzten Möglichkeiten zur Vereinfachung der Automatisierungsaufgabe zurückführen lassen. Daher gelten die umgesetzten Möglichkeiten als verifiziert. Dabei muss jedoch angeführt werden, dass aus Gründen der Verhältnismäßigkeit nicht alle identifizierten Abweichungen mikroskopisch —also einzeln — betrachtet sind und auch die zurückgelegte Strecke nicht für eine Validierung ausreicht.

Für die Anwendung von *Silent Testing* ist eine bestehende Straßenbahn des Darmstädter Nahverkehrs mit Sensoren und Messrechnern zur Umfeld erfassung umgerüstet worden. Als besonderes Alleinstellungsmerkmal ist diese Straßenbahn weiterhin mit menschlichem Fahrer im Linienebetrieb eingesetzt, was die Anwendung von *Silent Testing* auf 12.767 km aufgezeichneten Messdaten des realen Straßenbahnbetriebs mit Fahrgästen ermöglicht hat. Zur Anwendung von *Silent Testing* ist jedoch neben einem OuT sowie Messdaten auch eine Vergleichsmetrik von Mensch und Maschine erforderlich, um relevante Abweichungen aufzudecken. Bisherige Anwendungen im Kraftfahrzeugbereich fokussieren sich auf reine objektbasierte Metriken. Ein

solches Vorgehen setzt einerseits die Erkennung der umgebenden Objekte wie auch die korrekte Klassifikation dieser als Hindernis voraus. Genau dies ist im komplexen urbanen Raum mit Verdeckungen, kleineren Hindernissen wie Personen statt nur Kraftfahrzeugen und schwer erkennbaren Intentionen von Verkehrsteilnehmern jedoch besonders anspruchsvoll. Weiterhin bleiben bei diesem reinen Vergleich mit Objektmetriken sowohl Fahrerreaktionen wie auch mögliche falsche OuT Reaktionen zu weiteren Anforderungen wie die Beachtung von LSA, Halt an Haltestellen etc. unberücksichtigt. Aufgrund ihrer Spurbindung wartet die Straßenbahn mit einem reduzierten 1D-Verhaltensraum<sup>202</sup> auf, was den Vergleich grundsätzlich vereinfacht. Als Konsequenz dieser Gründe und aufgrund der Erstmaligkeit der hier aufgezeigten Anwendung ist als Vergleichsmetrik zur Identifikation von abweichendem Verhalten die Differenzbeschleunigung  $|\Delta a| = |a_{\text{OuT}} - a_{\text{Fahrer}}|$  sowie ein Schwellwert  $a_{\text{krit}} = 2,0 \text{ m/s}^2$  gewählt. Anhand des Vorzeichens von  $\Delta a$  bei Überschreiten des Schwellwertes ist zusätzlich eine Klassifikation der identifizierten Abweichungen in  $\mathcal{A}^+$  und  $\mathcal{A}^-$  erfolgt. Für  $\mathcal{A}^-$  ist als Hinweis auf die auslösende Ursache das aktive Verhaltensmodul des OuT bekannt, was eine weitere Klassifikation der  $\mathcal{A}^-$  in die übergeordneten Themenfelder *Lichtsignalanlage*, *Haltestellen*, *Höchstgeschwindigkeit* und *Objekte* ermöglicht. Mit der Nutzung dieser Vergleichsmetrik gilt die in Kapitel 2.3 gestellte Forschungsfrage FF.3 zur Gestaltung des Vergleichs als beantwortet.

### FF.3

Wie kann zur Anwendung von *Silent Testing* ein Vergleich von menschlichem und maschinellem Verhalten bei der Automatisierung von Straßenbahnen gestaltet werden?

Durch die Anwendung von *Silent Testing* sind in Kapitel 5 mehrere Abweichungen in Form von  $\mathcal{A}^+$  und  $\mathcal{A}^-$  identifiziert. Die Auswertung ist sowohl statistisch als makroskopische Betrachtung, wie auch als Einzelfallanalyse in Form einer mikroskopischen Betrachtung erfolgt. Die Untersuchung hat eine Vielzahl an verschiedenen Ursachen und Gründen für diese Abweichungen aufgedeckt. So sind nicht nur mehrere andersartige Herausforderungen an die Automatisierung von Straßenbahnen identifiziert, sondern auch aus anderen Domänen bekannte Schwierigkeiten wie der Einfluss von Nebel auf die Umfeldsensorik aufgezeigt. Teilweise warten letztere jedoch mit neuen Tragweiten für Straßenbahnen aufgrund unterschiedlicher Randbedingungen auf. So gilt z. B. das aufgezeigte Lidar-Blooming für alle Anwendungen von Lidar. Die Straßenbahn weist jedoch nicht nur besonders viele und besonders nah am Fahrschlauch angebrachte retroreflektierende Verkehrsschilder auf, sondern kann der Fehldetektion auch bei einer frühen Wahrnehmung aufgrund ihrer Spurbindung nicht ausweichen. Weiterhin sind nicht nur neue Herausforderungen oder bekannte Schwierigkeiten mit *Silent Testing* identifiziert, sondern wie oben bereits erläutert neue Möglichkeiten plausibilisiert. Darüber hinaus sind im Rahmen der Auswertung auch Ursachen identifiziert, welche sich auf Unzulänglichkeiten des OuT zurückführen lassen. So hat bspw. für den im vorherigen Kapitel aufgezeigten Fall der ausbleibenden

<sup>202</sup> Abgesehen von Weichen.

Reaktionen für das Signal F4 die Anwendung von *Silent Testing* als grundsätzlicher Schritt der allgemeinen Verifikation des OuT fungiert. Grundsätzlich sind jedoch auch eine Vielzahl falsch positiver Abweichungen identifiziert, bei denen der menschliche Fahrer z. B. nur auf eine LSA zurollt oder in Erwartung eines Fahrt zeigenden Signals bereits bei F0 losfährt. Einerseits sind diese fälschlichen Abweichungen durch die Wahl der simplen Vergleichsmetrik mit  $\Delta a$  bedingt. Andererseits handelt es sich hierbei um eine grundlegende Schwäche des *Silent Testing* Ansatzes. Auch bei komplexeren Vergleichsmetriken ist die Varianz des menschlichen Verhaltens so groß, dass sowohl falsch positive wie auch falsch negative Abweichungen nicht vollständig ausgeschlossen werden können. Dennoch ist die einleitende Motivation dieser Arbeit erfüllt. Es ist eine Methode zur Identifikation von Herausforderungen und Plausibilisierung neuer Möglichkeiten zur Automatisierung von Straßenbahnen erarbeitet. Diese Methode ist in Form von *Silent Testing* erstmals auf Straßenbahnen angewendet und verschiedene Herausforderungen sowie Möglichkeiten sind identifiziert und plausibilisiert. Die Forschungsfrage FF. 2 nach der Anwendbarkeit von *Silent Testing* auf Straßenbahnen ist somit beantwortet.

### FF. 2

Können mit *Silent Testing* als Werkzeug der Funktionsentwicklung Herausforderungen des automatisierten Fahrens von Straßenbahnen identifiziert und neuartige Lösungsansätze plausibilisiert werden?

Im Rahmen der praktischen Anwendung von *Silent Testing* sind verschiedenste Herausforderungen identifiziert. Dabei handelt es sich einerseits um Problemstellungen, die als eindeutige Entwicklungsaufgabe mit bestehenden Methoden gelöst werden können. Andererseits sind auch Herausforderungen identifiziert, welche tiefgehende Forschung und neuartige Lösung erfordern. Nicht als alleinige Herausforderungen, aber als die wesentlichen werden die Nachfolgenden betrachtet:

- **Lichtsignalanlagen:** Aufgrund einer Vielzahl an Faktoren wie die grundsätzlich schlechtere Erkennbarkeit gegenüber dem Kraftfahrzeugbereich, den geringen Erfahrungswerten und verfügbaren Datensätzen sowie die grundsätzlichen Herausforderungen der kamerabasierten Detektionen gelten LSA — unter der Prämisse keine Änderungen an der Infrastruktur vorzunehmen — als eine der größten Herausforderungen. Mit V2I oder einer anderweitigen modernen Zugsicherung ist jedoch eine Lösung dieser Herausforderung denkbar.
- **Herausforderungen der Sensoren:** Auch wenn Blooming oder Objekte, die zu nah am Fahrschlauch angebracht sind, auch als Fehlerquelle in anderen Domänen gelten, sind diese aufgrund der Spurbindung und des häufigen Auftretens (bspw. Verkehrsschilder, Fahrgastunterstände etc.) als besondere Herausforderung für Straßenbahnen zu bewerten.
- **Herausforderungen der Detektion:** Insbesondere im Rahmen der  $\mathcal{A}^-$  ist eine Vielzahl

an verschiedenen Ursachen für eine erschwerte Objektdetektion identifiziert. Aufgrund der Nähe stellen andere Fahrzeuge des ÖPNV und insbesondere Personen in Innenstädten spezifische Herausforderung für die Automatisierung der Straßenbahnen dar. Im direkten Vergleich mit dem Kraftfahrzeugbereich ist zusätzlich die veränderliche Vegetation als besondere Herausforderung zu bewerten — die jedoch in ähnlicher Weise auch für Vollbahnen gilt.

- **Intentionserkennung:** Zwar wartet auch der Kraftfahrzeugbereich mit einer Vielzahl an verschiedenen Herausforderungen bezüglich der Erkennung der Intentionen von anderen Verkehrsteilnehmern auf, jedoch ergeben sich für die Straßenbahn aufgrund ihrer Einsatzumgebung an Haltestellen und in Fußgängerzonen neue Randbedingungen für diese Herausforderungen.

Neben diesen wesentlichen Herausforderungen sind wie zuvor angeführt auch weitere Herausforderungen oder neuartige Anforderungen der Automatisierung von Straßenbahnen, wie das Verhalten zu bereits belegten Haltestellen identifiziert. Die grundsätzliche Motivation zur Durchführung dieser Arbeit gilt damit als erfüllt und die Hauptforschungsfrage FF. 1 nach den größten Herausforderungen ist beantwortet und ausführlicher in Kapitel 5 diskutiert.

#### FF. 1

Welche wesentlichen neuen Herausforderungen ergeben sich bei der Automatisierung von Straßenbahnen?

## 6.2 Ausblick

Im Rahmen dieser Arbeit sind erstmalig Herausforderungen an die Automatisierung von Straßenbahnen systematisch abgeleitet und neue technische Möglichkeiten unter realen Umgebungsbedingungen getestet. Als wesentlichen nächsten Schritt zur Automatisierung der Straßenbahn wird vorgeschlagen, die in dieser Arbeit aufgezeigten Herausforderungen als tiefergehende Fragestellungen einzeln zu lösen. Aufgrund der neuen Randbedingungen der Straßenbahn ergeben sich hierbei Fragen, die über eine reine Entwicklungsarbeit im Form von zu erbringender Forschung hinausgehen. Insbesondere die Intentionserkennung stellt ein breites und umfangreiches Forschungsthema auf. Einerseits sind hier aus dem weiter fortgeschrittenen Kraftfahrzeugbereich Ansätze zu übertragen, andererseits ist auf die domänenspezifischen neuen Anforderungen, wie Haltestellen oder Fußgängerzonen, einzugehen und diese entsprechend zu berücksichtigen.

Vor dem Hintergrund der aufgezeigten Herausforderungen und Unzulänglichkeiten, sowie unter Berücksichtigung des vergleichsweise geringeren Umsatzvolumens von Straßenbahnen und der damit einhergehenden geringeren finanziellen Möglichkeiten im Vergleich zu Kraftfahrzeugentwicklung ist die konkretisierte Referenzarchitektur sowie die Implementierung bezüglich des

Lidar-Clusterings zu überarbeiten. Einerseits sind falsch positive Objekte bspw. durch Vegetation oder Blooming zu reduzieren, andererseits ist dabei auch der Sicherheitsnachweis sowie die Aufwände bezüglich maschinell gelernter Detektoren zu berücksichtigen. Hierzu bedarf es weitere Forschung zur Detektions-Architektur — wie bspw. die Fusion eines gelernten Detektors mit Clustering — und der genauen Umsetzung.

Neben der Umfeldwahrnehmung von Objektdetektion sind insbesondere LSA aufgrund einer Vielzahl an Ursachen als Herausforderung der Automatisierung von Straßenbahnen aufgedeckt. Wie bereits im Rahmen der Teilevaluation der  $\mathcal{A}_{\text{LSA}}^-$  aufgezeigt, stellt jedoch gerade V2I eine vielversprechende Möglichkeit dar, diese Herausforderungen zu lösen. Dabei sind verschiedene Motivatoren zur funkgestützten Erfassung des Signalzustandes, wie das begrenzte Einsatzgebiet, nochmals höher als in anderen Domänen. Jedoch bedarf es neben den technischen Fragestellungen zu V2I im Bereich der Straßenbahn auch die Wirtschaftlichkeit zu betrachten. Insbesondere für letzteres sollte beachtet werden, dass ein solches Teilsystem auch bereits als Assistenz schon heute einen Mehrwert für den menschlichen Fahrer darstellt.

Die im Rahmen dieser Arbeit entwickelte Methode um *Silent Testing* hat mit der gewählten Vergleichsmetrik grundsätzlich Herausforderungen sowie Unzulänglichkeiten der Implementierung aufgedeckt. Gleichzeitig übersteigt die Vielzahl der identifizierten Abweichungen die Möglichkeiten einer vollständigen Einzelfallanalyse. Mit tiefergehenden Filteransätzen und insbesondere als iteratives Verfahren nach dem Lösen der aufgezeigten wesentlichen Herausforderungen verspricht eine wiederholte Anwendung von *Silent Testing* die Aufdeckung weiterer Herausforderungen aber auch Anforderungen an den Funktionsumfang der Automatisierung von Straßenbahnen.

Die eingesetzte Vergleichsmetrik mittels  $\Delta a$  nutzt bewusst die Eindimensionalität der Straßenbahn und hat grundsätzlich den Vorteil der geringen Komplexität. Andererseits ist insbesondere für  $\mathcal{A}_{v_{\text{max}}}^+$  eine Vielzahl falsch positiver Abweichungen erfasst, die durch die Varianz des menschlichen Fahrers sowie durch unterschiedliche Reaktionszeiten entstehen. Die bisherigen veröffentlichten Umsetzungen von *Silent Testing* im Bereich der Kraftfahrzeuge beschränken sich ausschließlich auf reine objektbasierte Metriken. Es besteht daher auch für andere Domänen der Bedarf an einer Vergleichsmetrik, welche die Varianz menschlichen Verhaltens, Reaktionszeiten sowie nicht nur Objekte, sondern weitere Verkehrselemente wie LSA berücksichtigt. Daher ist zukünftig auch die Entwicklung und Forschung zu einer solchen straßenbahnspezifischen oder domänenübergreifenden Vergleichsmetrik für den komplexen urbanen Raum zu betrachten.

## A Annahmen und Herleitungen

### A.1 Mindestgeschwindigkeiten zur Identifikation einer Kreuzungsabsicht

Die querenden Mindestgeschwindigkeit ist abhängig der Klasse festgelegt, um kreuzende Fußgänger zur Unterdrückung falsch positiver Bremsungen früh zu erkennen, jedoch sich innerhalb ihres Fahrstreifens bewegende PKW nicht fälschlich als kreuzend zu klassifizieren. Die Geschwindigkeiten sind in Tabelle A-1 aufgelistet.

Tabelle A-1: Geschwindigkeiten Klassifikation kreuzender Objekte.

Klasse	Geschwindigkeit
Personen (Fußgänger)	5 km/h
Alle anderen	10 km/h

Die maximale Geschwindigkeit entlang der Gleise Richtung der Bahn wird als erster Schätzwert auf 10 km/h begrenzt, um diagonales Überqueren der Gleise zu erlauben. Dabei ist dies ein Kompromiss zwischen nicht erkannten falsch negativen kritischen Hindernissen und der Vermeidung von falsch positiven Bremsungen.

Die im Rahmen der Fusion bestimmte Geschwindigkeit der  $\mathcal{O}_{\text{track}}$  ist in den Achsen des zum Tracking zugehörigen ENU repräsentiert. Im Rahmen der Abstandsbestimmung zu den Splines wird nicht nur der Abstand, sondern auch die entsprechende Position im Gleis identifiziert. Durch die Darstellung des Gleises als B-Splines lässt sich ohne zusätzlichen Aufwand die Tangente des Gleisverlaufes an der Stelle des  $\mathcal{O}_{\text{track}}$  bestimmen, mit welcher die im ENU gegebene Geschwindigkeit in eine Komponente entlang und quer zum Gleis zerlegt werden kann.

### A.2 ACC Regelung

Für die ACC Regelung entsprechend Winner et al.<sup>166b</sup> sind die Zeitkonstanten  $\tau_{d,v,\text{soll}}$  zu parametrisieren.  $\tau_{\text{soll}}$  ist im Kraftfahrzeugbereich die vom Fahrer wählbare Zeitlücke, die herstellerabhängig häufig einen Bereich von etwa 1–4 s abdeckt. Für die Verhaltensplanung der Straßenbahn wurde aufgrund deren Trägheit  $\tau_{\text{soll}} = 4$  s für ein defensives Verhalten gewählt. Entsprechend

der Literatur wird auf Einscheren mit einer leichten Bremsung mittels  $\tau_d \cdot \tau_v = 20 \text{ s}^2$  reagiert. Unter Wahl einer geringen Folgedynamik von  $\tau_v = 4 \text{ s}$  ergibt sich  $\tau_d = 5 \text{ s}$ .

## B Details Abweichungen

### B.1 $\mathcal{A}_{\text{LSA}}^-$ Lichtsignalanlagen mit Detektion

Zur Identifikation systematischer Ursachen sowie bevorzugt mikroskopisch zu betrachtender LSA werden die  $\mathcal{A}_{\text{LSA}}^-$  mit Detektion ihren jeweiligen LSA zugeordnet und auf die Anzahl aller Vorbeifahrten an diesen, also auch solchen ohne Abweichung, bezogen. Hierdurch werden LSA hervorgehoben, die besonders problematisch bezüglich der Reaktion auf ein F0 auffallen. Gruppieren nach der Höchstgeschwindigkeit an der LSA in Abb. B-1 dargestellt. Jeder Balken repräsentiert eine LSA. Da jedoch entgegen der erlaubten Höchstgeschwindigkeit der menschliche Fahrer an der Stelle (wiederholt) signifikant langsamer gefahren sein kann, sind die Abweichungen pro LSA in Abb. B-1 zusätzlich farblich nach dem Abstand  $d_{\text{HP}}$  zwischen Bahn und dem zur jeweiligen LSA zugehörigem Haltepunkt bei Auftreten der Abweichung eingefärbt.

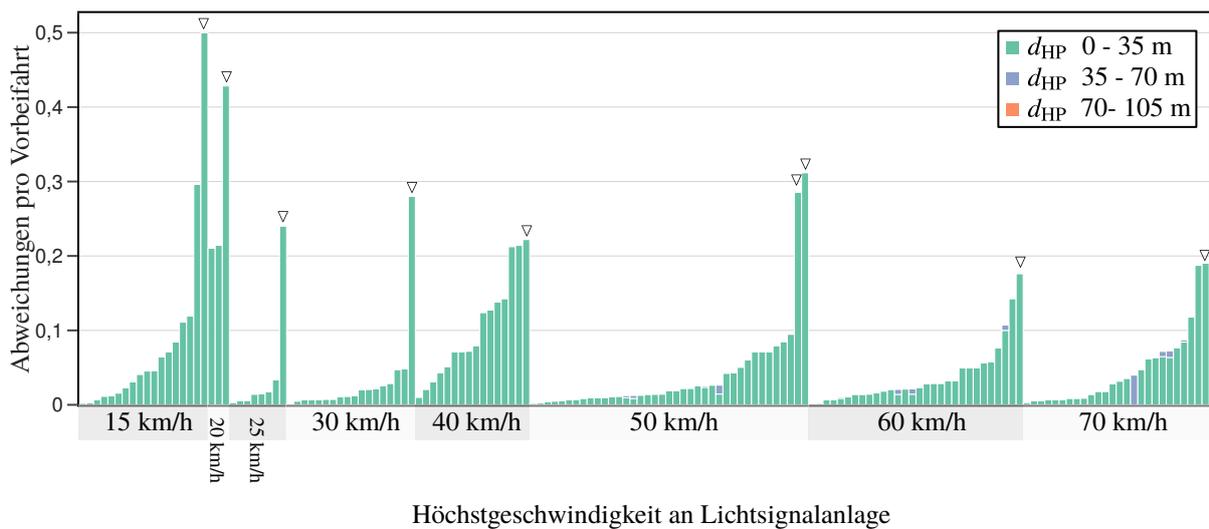


Abbildung B-1:  $\mathcal{A}_{\text{LSA}}^-$  mit Detektion bezogen auf die Anzahl aller Vorbeifahrten der jeweiligen Haltestelle. Gruppieren nach der für die an der LSA erlaubten Höchstgeschwindigkeit. Zusätzlich farblich nach dem Abstand  $d_{\text{HP}}$  zwischen Bahn und dem zur jeweiligen LSA zugehörigem Haltepunkt eingefärbt.

## B.2 $\mathcal{A}^-$ Lichtsignalanlagen ohne Detektion

Nachfolgend sind Beispiele gezeigt, die im Rahmen der mikroskopischen Betrachtung identifiziert sind und zu einer Reaktion des Systems in Form einer  $\mathcal{A}_{\text{LSA}}^-$  führen. Ohne Detektion meint dabei nicht pauschal ohne Erkennung eines Lichtbalkens im Kamerabild, sondern ein Signalzustand der aus der eindeutigen Zuweisung aller erkannten Zeichen in Kamerabildern erfolgt.



(a) Gegenlicht.

(b) Einzelne Regentropfen.

(c) Nebel.



(d) Bewegungsunschärfe durch lange Belichtung aufgrund der Dämmerung.

(e) Verdeckung durch eine Baustelle. In der Nahsichtkamera ist das Signal sichtbar.

(f) Zwei LSA hintereinander. Je nach Blickwinkel beide in ROI.



(g) Teilverdeckung mit Bauzaun reicht bereits aus.

(h) Zu weit entfernt für die Nahsichtkamera.



(i) Helligkeitsunterschied des Signals in linker und rechter Fernsichtkamera aufgrund von gepulstem LED Licht.

Abbildung B-2: Beispiele 2/2 für Herausforderungen die auch andere Domänen wie automatisierte Pkw betreffen.

## B.3 A<sup>-</sup> Höchstgeschwindigkeit

Nachfolgend ist eine temporäre (über ein Jahr) Geschwindigkeitsbeschränkung aufgrund einer Baustelle und damit Verschiebung des Fahrstreifens des Individualverkehrs gezeigt. Die Geschwindigkeitsbeschränkung wurde sehr selten jedoch bis zu 12 km/h überschritten. Zusätzlich war Geschwindigkeitsbeschränkung für alle Messdaten in der Karten hinterlegt, in der Realität jedoch nur temporär aktiv.

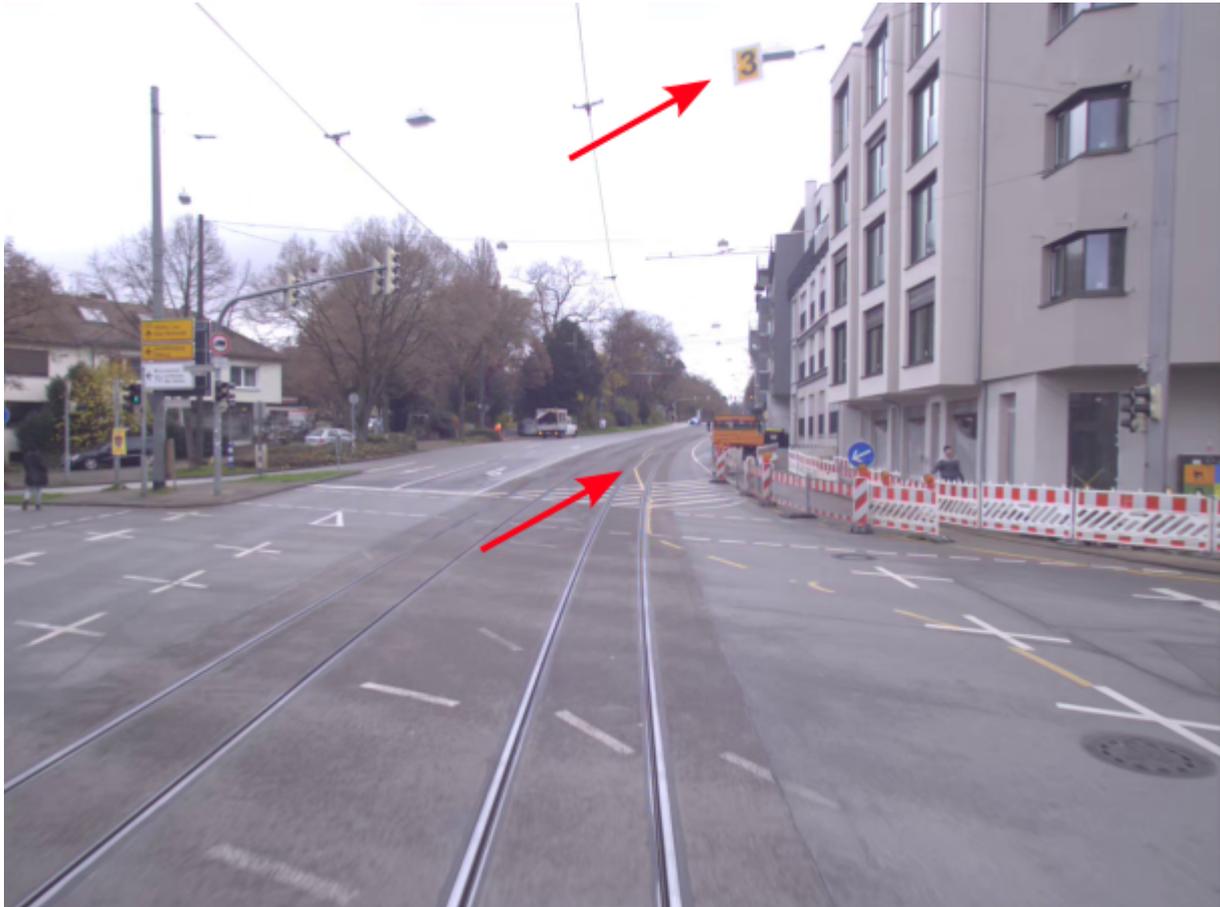


Abbildung B-3: Temporäres (über ein Jahr) 30 km/h Limit sowie Umlegung des Fahrstreifens des Individualverkehrs aufgrund von Bauarbeiten.

## B.4 Klassifikation von Objekten ohne Abweichung

Zur Bewertung der kamerabasierten Klassifikation werden alle Objekte, die kein  $\mathcal{A}^-$  verursachen, auf die jedoch mit einer Anpassung von  $a_{\text{OUT}}$  reagiert wird, klassifiziert. In dem betrachteten Messdaten sind dazu 31.159 verschiedene Objekte (ohne die Objekte, die ein  $\mathcal{A}^-$  verursachen) enthalten. Wie nachfolgend Abb. B-4 (a) zeigt, ist mit etwa 58 % die häufigste Klasse *unbekannt*. Da es jedoch auch ohne  $\mathcal{A}^-$  falsch positive Reaktionen geben kann, sind in Abb. B-4 (b) nur Objekte berücksichtigt, auf die mindestens 1 s reagiert wird. Die Anzahl der unbekannt Objekte reduziert sich auf etwa 28 %.

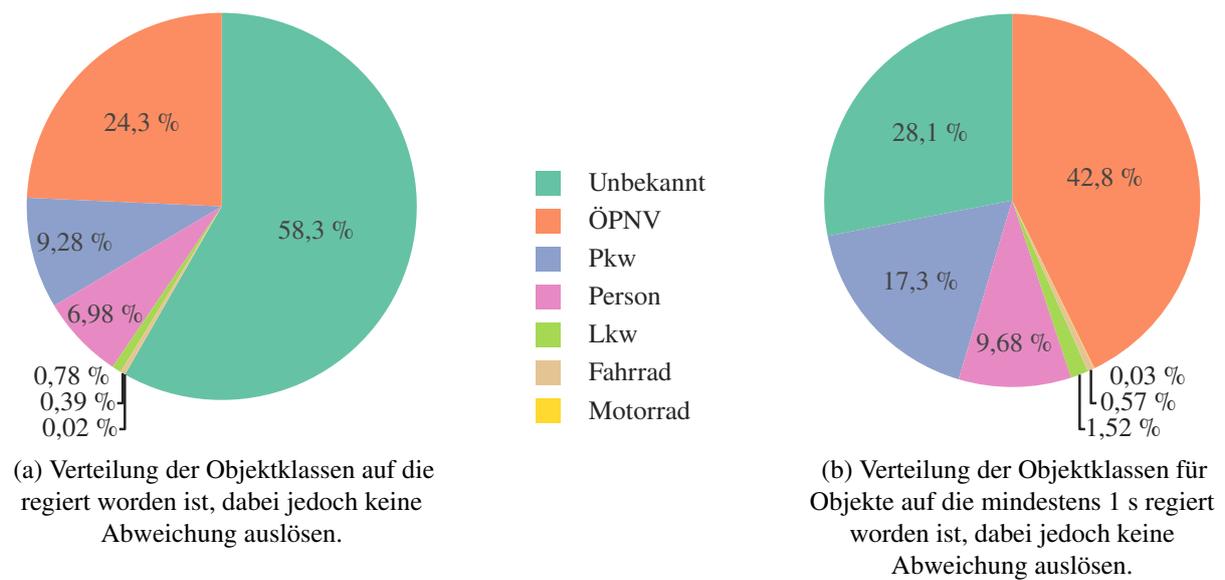


Abbildung B-4: Klassenverteilung von Objekten der Umgebung.

## B.5 $\mathcal{A}_{\bar{O}}$ örtliche Hotspots

Nachfolgende Abbildung zeigt die 30 größten (im Sinne des Vergleichswertes  $\mathcal{G}$ ) Gruppen an  $\mathcal{A}_{\bar{O}}$  als sogenannte Hotspots im gesamten Darmstädter Straßenbahnnetz.

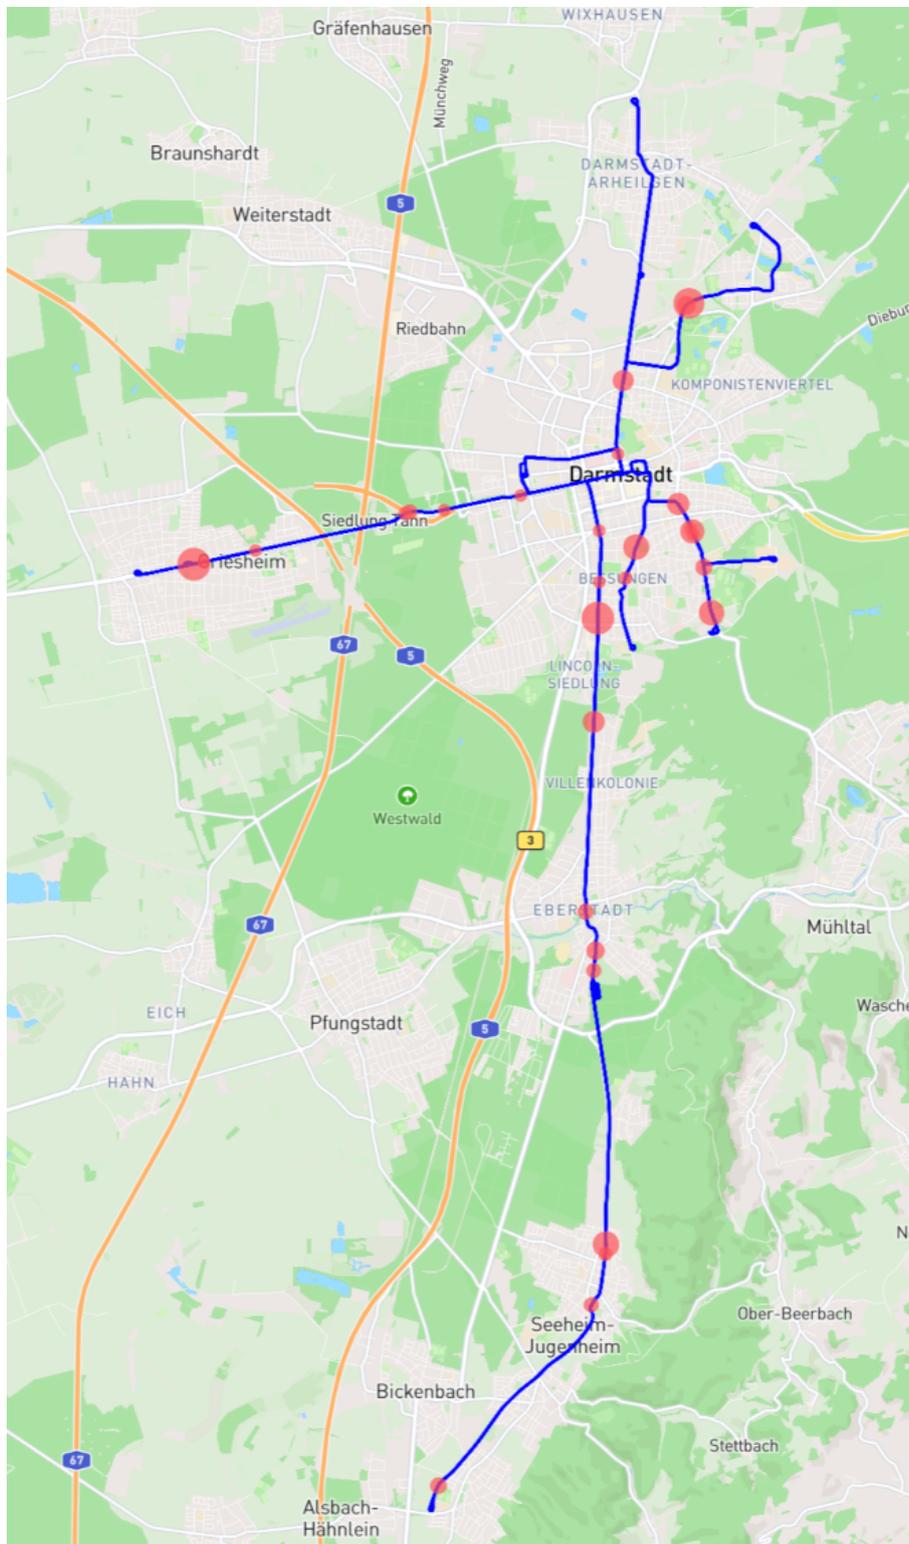


Abbildung B-5: Karte  $\mathcal{A}_{\bar{O}}$  Hotspots im ganzen Streckennetz. © MapBox © OpenStreetMap.

## B.6 $\mathcal{A}_O^-$ Fehldetektionen aufgrund der Sensornähe

Nachfolgende Abbildung zeigt neben dem im Hauptteil beschriebenen Fahrgastunterstände weitere Beispiele durch falsch positive Lidar Detektionen aufgrund der Nähe zu Objekten.

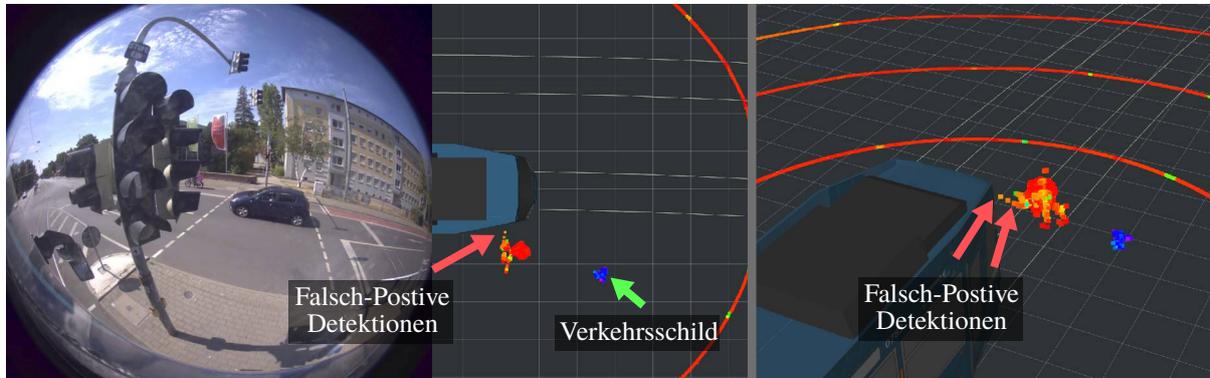


Abbildung B-6: Velodyne VLP-32C Lidarsensorfehler aufgrund der Nähe zur LSA.

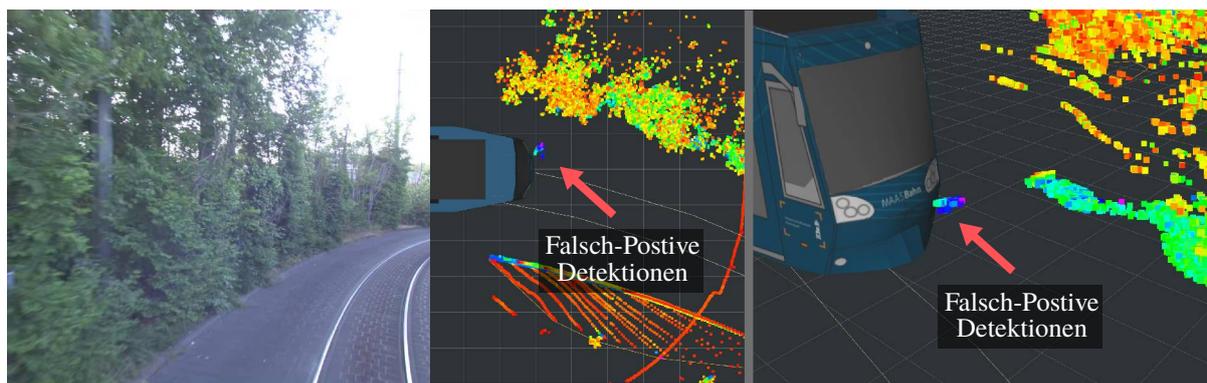


Abbildung B-7: Ibeo Scala Lidarsensorfehler aufgrund der Nähe zu einer Hecke.

## B.7 $\mathcal{A}_{\bar{O}}$ aufgrund von Nebel

Nachfolgend sind weitere Beispiele für  $\mathcal{A}_{\bar{O}}$  aufgrund vom Nebel dargestellt. Abb. B-8 zeigt für zwei Messungen an unterschiedlichen Tagen ein Effekt, der sich in einer Vielzahl der Messungen mit Nebel zeigt. Innerhalb des horizontalen FoV des Ibeo Scala kommt es zu kaum fehlerhaften Detektionen innerhalb des Velodyne Lidar VLP-32C.

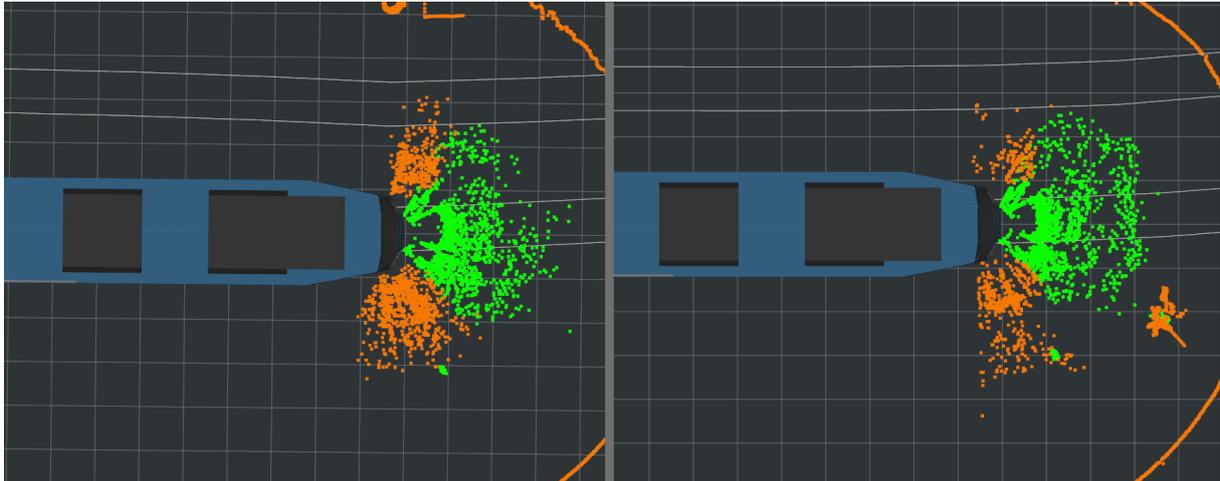


Abbildung B-8: Übergang Nebel-effekt zwischen den beiden Sensoren.

Neben den Detektionen im unmittelbaren Nahbereich um die Sensoren zeigen sich wie beispielhaft nachfolgend in Abb. B-9 gezeigt, auch Detektionen aufgrund von Nebel in weiterer Entfernung. In dem gezeigten Ausschnitt sind 244 Lidar Punkte in etwa 8 m Entfernung zu erkennen.

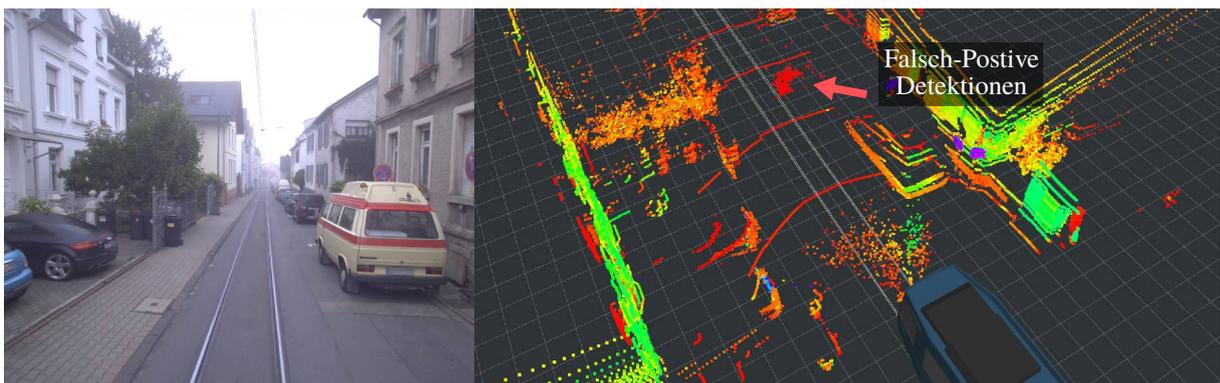


Abbildung B-9: Anhäufung von falschen Detektionen in etwa 8 m Entfernung aufgrund von Nebel im Velodyne Lidar VLP-32C.

## B.8 Abweichungen aufgrund fehlerhafter Intentionserkennung

Ergänzend zum Hauptteil sind nachfolgend weitere Beispiele für von fehlerhafter Intentionserkennung dargestellt. In Abb. B-10 ist zeitlich das Kamerabild für einen Kreuzungsvorgang von zwei Personen in der Fußgängerzone gezeigt. Der menschliche Fahrer bremst zu Beginn mit etwa  $-1,0 \text{ m/s}^2$  für etwa 2 s, da die beiden Personen augenscheinlich die herannahende Bahn noch nicht beachten. Kurz nachdem die Personen den Fahrschlauch betreten haben, bemerken sie die Bahn und gehen zunächst einige Schritte zurück. Daraufhin beginnen sie erneut, dieses Mal rennend, die Gleise zu überqueren. Der menschliche Straßenbahnfahrer bricht die Bremsung in diesem Moment ab. Aufgrund des kurzzeitig stehen bzw. sogar zurückgehen der Personen versagt die reine geschwindigkeitsbasierte Intentionserkennung, die im Rahmen der Referenzimplementierung umgesetzt ist.



Abbildung B-10: Beispiel Versagen der Kreuzungsvorhersage. Die zwei Personen beginnen im Innenstadtbereich die Gleise zu überqueren, während die Straßenbahn noch etwa 20 m entfernt ist. Erst nachdem sie im Fahrschlauch der Ego-Straßenbahn sind, bemerken sie die Straßenbahnen und gehen zunächst wieder einige Schritte zurück. Daraufhin beginnen sie erneut, diesesmal rennend, die Gleise zu überqueren.

## B.9 Weitere Ursachen für $\mathcal{A}_{\bar{\mathcal{O}}}$

Nachfolgend sind in Abb. B-11 verschiedene Beispiele gezeigt, in denen ein Vogel zu einer  $\mathcal{A}_{\bar{\mathcal{O}}}$  führt. Aufgrund der vertikalen Lidar Ebenen, des umgesetzten Filters zu Objekthöhen von 10 cm sowie des kurzen Aufenthalts im Fahrschlauch, sind die identifizierten Abweichungen alle unter 1 s Dauer.

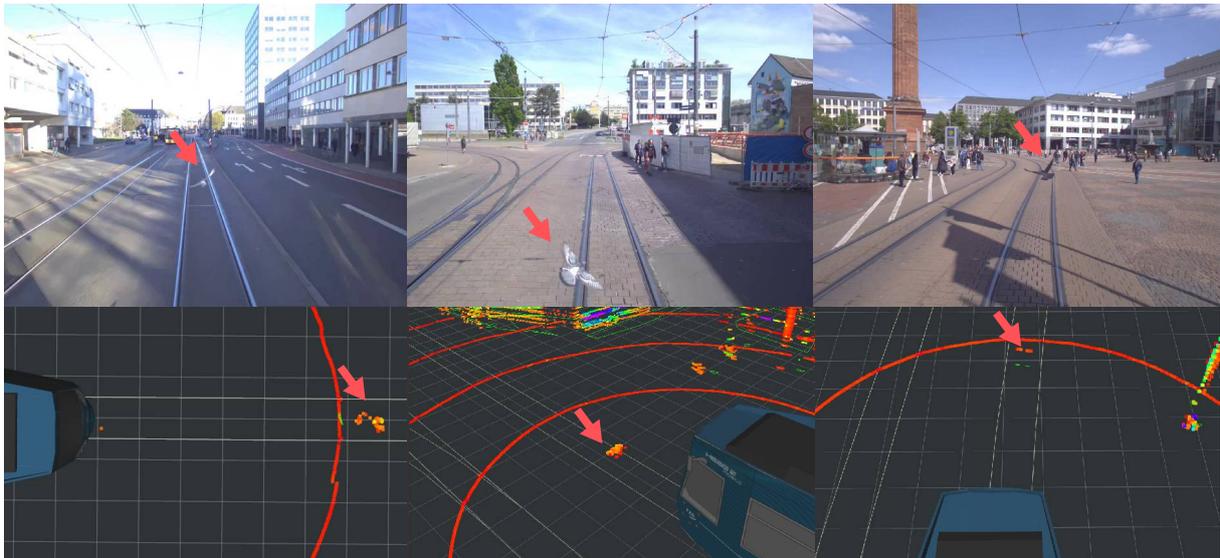


Abbildung B-11: Beispiel  $\mathcal{A}_{\bar{\mathcal{O}}}$  durch Vögel.

In der Fusion auf Objektlistenebene wird von den eingesetzten Continental SRR52x Radaren lediglich die Geschwindigkeit der Objekte verwendet. Wie im Hauptteil erläutert, verfügen die eingesetzten Radare nicht über Objekthypothesen für Straßenbahnen und Busse. Technologisch ist die möglich, jedoch in der eingesetzten Variante nicht vorhanden. Daraufhin werden diese als eine Vielzahl von Pkw (je mit der höchsten Existenzwahrscheinlichkeit des Sensors) ausgegeben. Die Orientierung dieser fälschlichen Pkw stimmt jedoch nicht mit der realen Straßenbahn oder Bus überein. Nachfolgend ist in Abb. B-12 die Folgefahrt auf einen Bus bei einer entgegenkommenden Straßenbahn gezeigt.

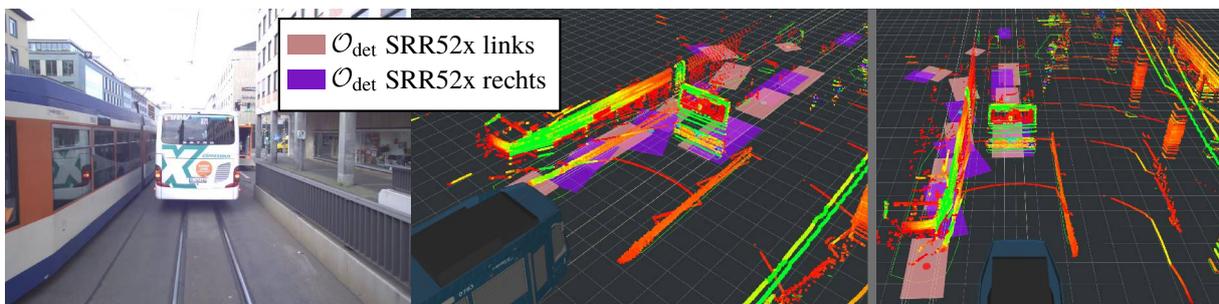


Abbildung B-12: Radar Boundingboxen der entgegenkommenden Straßenbahn ragen in die mit Lidar bestimmten Cluster des Busses hinein.

In der obigen Abbildung ragen die mittels Radar bestimmten Boundingboxen der entgegenkommenden Straßenbahn in die mit Lidar bestimmten Cluster des Busses hinein. Aufgrund von Doppeldeutigkeiten und fehlender Plausibilisierung in der Fusion, kommt es vereinzelt zu kurzen Zuweisungen der Geschwindigkeit des entgegenkommenden Fahrzeuges auf das Objekt der Fahrgasse. Hierdurch ist für die Verhaltensplanung nun ein Fahrzeug im Fahrschlauch, welches sich mit hoher relativer Geschwindigkeit nähert. Die Verhaltensplanung reagiert mit einer starken Bremsung, was fälschlich eine  $\mathcal{A}_O^-$  auslöst.

## B.10 $\mathcal{A}_{v_{\max}}^+$ örtliche Hotspots

Nachfolgende Abbildung zeigt die 30 größten (im Sinne des Vergleichswertes  $\mathcal{G}$ ) Gruppen an  $\mathcal{A}_{v_{\max}}^+$  als sogenannte Hotspots im gesamten Darmstädter Straßenbahnnetz.

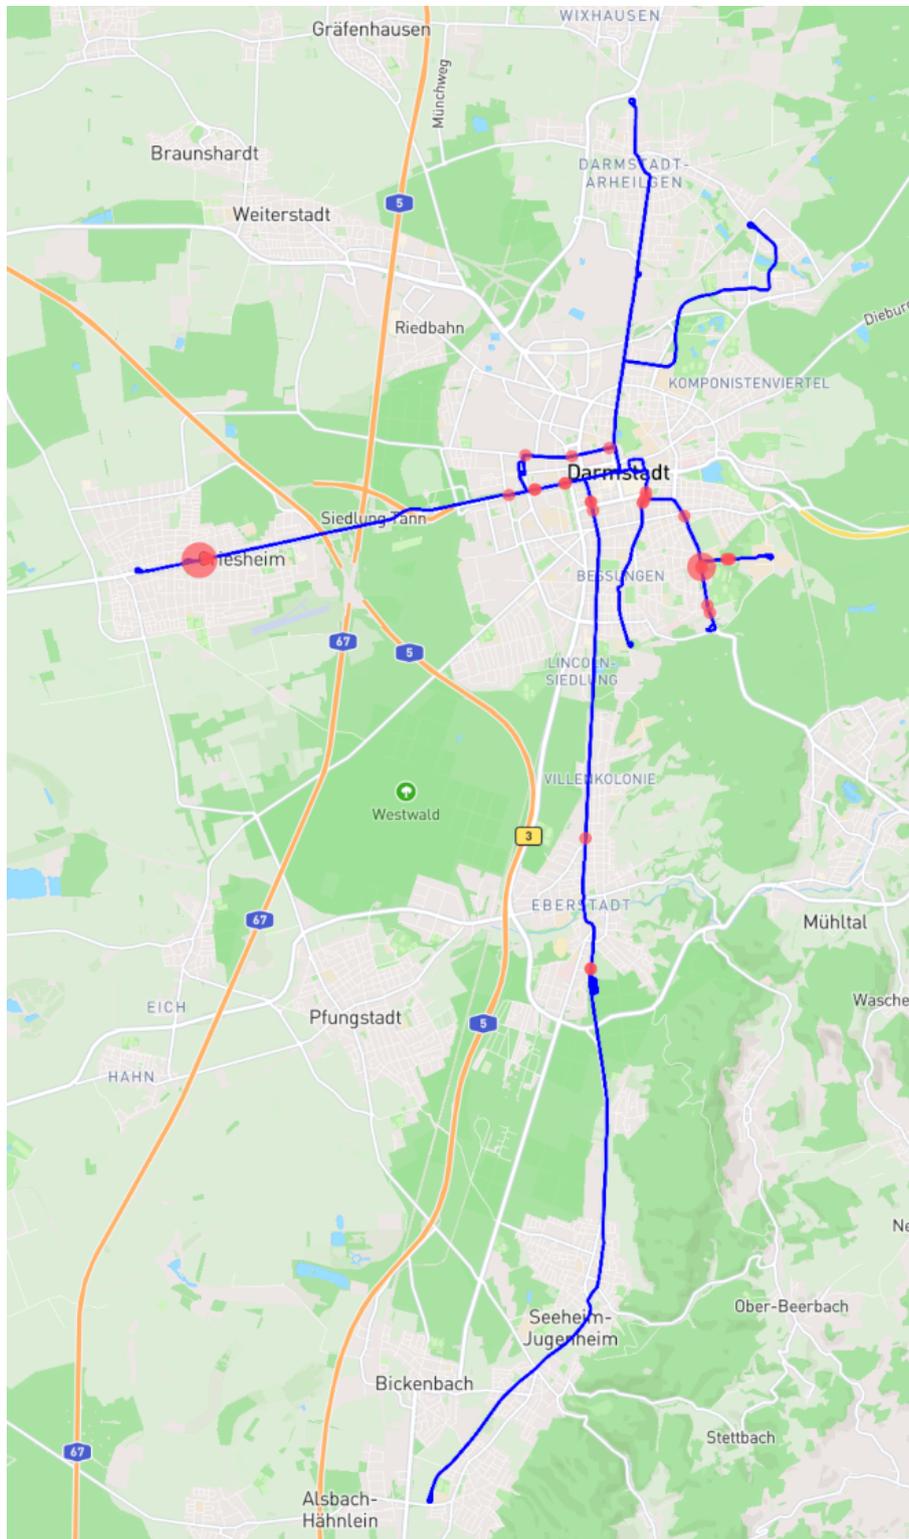


Abbildung B-13: Karte  $\mathcal{A}_{v_{\max}}^+$  Hotspots im ganzen Streckennetz. © MapBox © OpenStreetMap.

## Literaturverzeichnis

**Ainsalu, J. et al.: Sota Automated Buses (2018)**

Ainsalu, Jaagup; Arffman, Ville; Bellone, Mauro; Ellner, Maximilian; Haapamäki, Taina; Haavisto, Noora; Josefson, Ebba; Ismailogullari, Azat; Lee, Bob; Madland, Olav; Madžulis, Raitis; Müür, Jaanus; Mäkinen, Sami; Nousiainen, Ville; Pilli-Sihvola, Eetu; Rutanen, Eetu; Sahala, Sami; Schønfeldt, Boris; Smolnicki, Piotr Marek; Soe, Ralf-Martin; Sääski, Juha; Szymańska, Magdalena; Vaskinn, Ingar; Åman, Milla: State of the Art of Automated Buses, in: Sustainability, Vol. 10, S. 3118, 2018

**Altamimi, Z. et al.: The ITRS and ETRS89 Relationship (2011)**

Altamimi, Zuheir; Boucher, C.: The ITRS and ETRS89 Relationship: New Results from ITRF2000, 2011

**Anz, R.: Prüfverfahren Kollisionswarnsysteme für Straßenbahnen (2020)**

Anz, Ruprecht: Prüfverfahren zur Systemverifikation von Kollisionswarnsystemen für Straßenbahnen, in: ETR Fahrzeuge & Komponenten, 2020

**Bach, J. et al.: Model based scenario specification (2016)**

Bach, Johannes; Otten, Stefan; Sax, Eric: Model based scenario specification for development and test of automated driving functions, in: 2016 IEEE Intelligent Vehicles Symposium (IV), S. 1149–1155, 2016

**Bahn Manager: Autonome Tram findet ihren Weg im Depot (2021)**

Bahn Manager: Autonome Tram findet ihren Weg im Depot, 2021

**Beismann, H. et al.: Schienenfahrzeuge für den fahrerlosen U-Bahnbetrieb (2005)**

Beismann, H.; Schmidt, V.: Schienenfahrzeuge für den fahrerlosen U-Bahnbetrieb, in: e & i Elektrotechnik und Informationstechnik, Vol. 122, a13–a18, 2005

**Bender, P. et al.: Lanelets (2014)**

Bender, P.; Ziegler, J.; Stiller, C.: Lanelets: Efficient map representation for autonomous driving, in: 2014 IEEE Intelligent Vehicles Symposium Proceedings, S. 420–425, 2014

**Bengler, K. et al.: FAS und Automatisiertes Fahren (2021)**

Bengler, Klaus; Dietmayer, Klaus; Eckstein, Lutz; Stiller, Christoph; Winner, Hermann: Fahrerassistenzsysteme und Automatisiertes Fahren, in: Pischinger, Stefan; Seiffert, Ulrich (Hrsg.): Vieweg Handbuch Kraftfahrzeugtechnik, Springer Fachmedien, 2021

**BGBI: Straßenverkehrs-Ordnung (2013)**

BGBI: Straßenverkehrs-Ordnung, in der Fassung vom 28.08.2023, 2013

**BGBI: BOStrab (1987)**

BGBI: Verordnung über den Bau und Betrieb der Straßenbahnen, Fundstellennachweis: 9234-5, in der Fassung vom 01.10.2019, 1987

**Bogoslavskiy, I. et al.: Efficient Online Segmentation for Sparse 3D Laser Scans (2017)**

Bogoslavskiy, Igor; Stachniss, Cyrill: Efficient Online Segmentation for Sparse 3D Laser Scans, in: PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science, Vol. 85, S. 41–52, 2017

**Bogoslavskiy, I. et al.: Fast range image-based segmentation (2016)**

Bogoslavskiy, Igor; Stachniss, Cyrill: Fast range image-based segmentation of sparse 3D laser scans for online operation, in: 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), S. 163–169, 2016

**Böhringer, F. et al.: Location in railway traffic (2006)**

Böhringer, Frank; Geistler, Andreas: Location in railway traffic: generation of a digital map for secure applications, in: (Hrsg.): Computers in Railways X: Computer System Design and Operation in the Railway and Other Transit Systems, WIT Press, 2006

**BOSCH: Datenblatt TFCW (2021)**

BOSCH: Datenblatt Tram forward collision warning system, URL: [https://www.bosch-engineering.com/media/downloads/certificate\\_tfcw.pdf](https://www.bosch-engineering.com/media/downloads/certificate_tfcw.pdf), 2021

**BOSCH: Ten years of developing tram assistance systems (2022)**

BOSCH: Ten years of developing tram assistance systems at Bosch Engineering, URL: <https://www.bosch-presse.de/pressportal/de/en/ten-years-of-developing-tram-assistance-systems-at-bosch-engineering-245661.html>, 2022, aufgerufen 07. 12. 2023

**Bosch: PM Beifahrer für Straßenbahnen (2016)**

Bosch: Pressemeldung Elektronischer Beifahrer für Straßenbahnen, URL: <https://www.bosch-presse.de/pressportal/de/de/elektronischer-beifahrer-fuer-strassenbahnen-44870.html>, 2016, aufgerufen 06. 09. 2023

**Buehler, M. et al.: The DARPA Urban Challenge (2009)**

Buehler, Martin; Iagnemma, Karl; Singh, Sanjiv: The DARPA Urban Challenge: Autonomous Vehicles in City Traffic, Springer Tracts in Advanced Robotics, Vol. 56, Springer, 2009

**Caesar, H. et al.: nuScenes (2020)**

Caesar, Holger; Bankiti, Varun; Lang, Alex H.; Vora, Sourabh; Liong, Venice Erin; Xu, Qiang; Krishnan, Anush; Pan, Yu; Baldan, Giancarlo; Beijbom, Oscar: nuScenes: A Multimodal Dataset for Autonomous Driving, in: S. 11621–11631, 2020

**CAF: Connected and automated transport (2023)**

CAF: Connected and automated transport, URL: <http://www.caf.net/en/innovacion-tecnologia/movilidad-conectada-automatizada.php>, 2023, aufgerufen 07. 12. 2023

**Campbell, S. et al.: Sensor Technology in Autonomous Vehicles (2018)**

Campbell, Sean; O'Mahony, Niall; Krcpalcova, Lenka; Riordan, Daniel; Walsh, Joseph; Murphy, Aidan; Ryan, Conor: Sensor Technology in Autonomous Vehicles : A review, in: 2018 29th Irish Signals and Systems Conference (ISSC), S. 1–4, 2018

**Censi, A. et al.: Liability, Ethics, and Culture-Aware Behavior Specification (2019)**

Censi, Andrea; Slutsky, Konstantin; Wongpiromsarn, Tichakorn; Yershov, Dmitry; Pendleton, Scott; Fu, James; Frazzoli, Emilio: Liability, Ethics, and Culture-Aware Behavior Specification using Rulebooks, URL: <http://arxiv.org/abs/1902.09355>, 2019, aufgerufen 04. 10. 2023

**China Daily: Guideline unveiled (2023)**

China Daily: Guideline unveiled to make public use of autonomous driving vehicles safer, URL: <http://global.chinadaily.com.cn/a/202312/07/WS657100fba31090682a5f1d16.html>, 2023, aufgerufen 02. 01. 2024

**Ciszewski, T. et al.: RailTopoModel and RailML (2017)**

Ciszewski, T.; Nowakowski, W.; Chrzan, M.: RailTopoModel and RailML – data exchange standards in railway sector, in: Archives of Transport System Telematics, Vol. Vol. 10, issue 4, S. 10–15, 2017

**Clemenz, M.: Abbieger auf Irrwegen (2023)**

Clemenz, Matthias: Abbieger auf Irrwegen, 2023

**Cognitive Pilot: Tram Pilot (2019)**

Cognitive Pilot: Tram Pilot, URL: <https://en.cognitivepilot.com/products/cognitive-tram-pilot/>, 2019, aufgerufen 07. 12. 2023

**Continental: Future of Urban Rail (2018)**

Continental: Preventing Accidents for the Future of Urban Rail – Automotive Technology by Continental Is the Key, URL: <https://www.continental.com/en/press/press-releases/future-of-urban-rail/>, 2018, aufgerufen 07. 12. 2023

**Continental: Produktwebseite SRR52x (2023)**

Continental: Short Range Radar – SRR52x, URL: <https://www.continental-automotive.com/de/components/radars/short-range-radars/short-range-radar-srr52x.html>, 2023, aufgerufen 08. 12. 2023

**CPUC: Permits for Cruise and Waymo (2023)**

CPUC: Approves Permits for Cruise and Waymo To Charge Fares for Passenger Service in San Francisco, URL: <https://www.cpuc.ca.gov/news-and-updates/all-news/cpuc-approves-permits-for-cruise-and-waymo-to-charge-fares-for-passenger-service-in-sf-2023>, 2023, aufgerufen 02. 01. 2024

**Dangschat, J. S.: Automatisierter Verkehr – was kommt da auf uns zu? (2017)**

Dangschat, Jens S.: Automatisierter Verkehr – was kommt da auf uns zu?, in: Zeitschrift für Politikwissenschaft, Vol. 27, S. 493–507, 2017

**Dickmanns, E. D. et al.: Autonomous High Speed Road Vehicle Guidance (1987)**

Dickmanns, E. D.; Zapp, A.: Autonomous High Speed Road Vehicle Guidance by Computer Vision, in: IFAC Proceedings Volumes, Vol. 20, S. 221–226, 1987

**Dierckx, P.: Curve and Surface Fitting with Splines (1995)**

Dierckx, Paul: Curve and Surface Fitting with Splines, Clarendon Press, 1995

**Digitale Schiene: Sensors4Rail testete sensorbasierte Wahrnehmungssysteme (2023)**

Digitale Schiene: Sensors4Rail testete erstmals sensorbasierte Wahrnehmungssysteme, URL: <http://digitale-schiene-deutschland.de/Sensors4Rail>, 2023, aufgerufen 26. 09. 2023

**Digitale Schiene: Sensors4Rail Erfolgsprojekt geht zu Ende (2023)**

Digitale Schiene: Sensors4Rail: Ein Erfolgsprojekt geht zu Ende, URL: <http://digitale-schiene-deutschland.de/aktuelles/Erfolgsprojekt-Sensors4Rail-geht-zu-Ende>, 2023, aufgerufen 26. 09. 2023

**DIN EN 13452: Bremssysteme des öffentlichen Nahverkehrs (2005)**

DIN EN 13452: Bahnanwendungen - Bremsen - Bremssysteme des öffentlichen Nahverkehrs - Teil 1: Anforderungen an das Leistungsvermögen; Deutsche Fassung, 2005

**DIN EN 17343: Bahnanwendungen – Allgemeine Begriffe (2022)**

DIN EN 17343: Bahnanwendungen – Allgemeine Begriffe, 2022

**DIN EN 62290: Betriebsleit- und Zugsicherungssysteme (2015)**

DIN EN 62290: Bahnanwendungen - Betriebsleit- und Zugsicherungssysteme für den städtischen schienengebundenen Personennahverkehr, 2015

**DMV: Autonomous Vehicle Testing Permit Holders (2023)**

DMV: Autonomous Vehicle Testing Permit Holders, URL: <https://www.dmv.ca.gov/portal/vehicle-industry-services/autonomous-vehicles/autonomous-vehicle-testing-permit-holders/>, 2023, aufgerufen 02. 01. 2024

**DMV: Statement on Cruise LLC Suspension (2023)**

DMV: Statement on Cruise LLC Suspension, URL: <https://www.dmv.ca.gov/portal/news-and-media/dmv-statement-on-cruise-llc-suspension/>, 2023, aufgerufen 02. 01. 2024

**Dolk, V. et al.: Cooperative Automated Driving Scenarios (2018)**

Dolk, Victor; Ouden, Jos den; Steeghs, Sander; Devanesan, Jason Gideon; Badshah, Irfan; Sudhakaran, Adityen; Elferink, Koos; Chakraborty, Debayan: Cooperative Automated Driving for Various Traffic Scenarios: Experimental Validation in the GCDC 2016, in: IEEE Transactions on Intelligent Transportation Systems, Vol. 19, S. 1308–1321, 2018

**Ďuračik, M. et al.: Software architecture of Automatic Train Operation (2019)**

Ďuračik, Michal; Kršák, Emil; Meško, Matej; Ružbarský, Ján: Software architecture of Automatic Train Operation, in: 2019 IEEE 15th International Scientific Conference on Informatics, S. 000051–000054, 2019

**Edmund Optics: Datenblatt 68670EP (2017)**

Edmund Optics: Datenblatt 68670EP, 2017

**Ester, M. et al.: Density-based algorithm in large spatial databases (1996)**

Ester, Martin; Kriegel, Hans-Peter; Sander, Jörg; Xu, Xiaowei: A density-based algorithm for discovering clusters in large spatial databases with noise, in: Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, S. 226–231, 1996

**Fel, L. et al.: ODAS – An anti-collision assistance system (16)**

Fel, Landri; Zinner, Christian; Kadiofsky, Thomas; Pointner, Wolfgang; Weichselbaum, Johann; Reisner, Clemens: ODAS – An anti-collision assistance system for light rail vehicles and further development, in: 16

**Fischler, M. A. et al.: Random sample consensus (1981)**

Fischler, Martin A.; Bolles, Robert C.: Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography, in: Communications of the ACM, Vol. 24, S. 381–395, 1981

**Geiger, A. et al.: Benchmark 3D Object (2023)**

Geiger, Andreas; Lenz, Philip; Stiller, Christoph; Urtasun, Raquel: The KITTI Vision Benchmark Suite, URL: [https://www.cvlibs.net/datasets/kitti/eval\\_object.php?obj\\_benchmark=3d](https://www.cvlibs.net/datasets/kitti/eval_object.php?obj_benchmark=3d), 2023, aufgerufen 13. 10. 2023

**Geiger, A. et al.: Vision meets robotics: The KITTI dataset (2013)**

Geiger, Andreas; Lenz, Philip; Stiller, Christoph; Urtasun, Raquel: Vision meets robotics: The KITTI dataset, in: International Journal of Robotics Research (IJRR), 2013

**GeneSys: Datenblatt ADMA-G-Pro+ v35 (2023)**

GeneSys: Datenblatt ADMA-G-Pro+ v35, URL: <https://genesys-offenburg.de/wp-content/uploads/2023/07/GeneSys-Datasheet-ADMA-G-Pro-v35.pdf>, 2023

**Gerd Tasler et al.: Einführung des hochautomatisierten Fahrens (2018)**

Gerd Tasler; Volker Knollmann: Einführung des hochautomatisierten Fahrens – auf dem Weg zum vollautomatischen Bahnbetrieb, Vol. Eurailpress, 2018

**Gerrard, J.: Bombardier’s driver assistance system (2017)**

Gerrard, James: Bombardier’s driver assistance system for trams, in: 2017

**Glatzki, F. et al.: BSSD (2021)**

Glatzki, Felix; Lippert, Moritz; Winner, Hermann: Behavioral Attributes for a Behavior-Semantic Scenery Description (BSSD) for the Development of Automated Driving Functions, in: 2021 IEEE International Intelligent Transportation Systems Conference (ITSC), S. 667–672, 2021

**Grießbach, A. et al.: Maßnahmen Unfälle mit Straßenbahnen (2016)**

Grießbach, Andreas; Seiler, Nadja; Brannolte, Ulrich; Plank-Wiedenbeck, Uwe; Bakaba, Jean Emmanuel; Ortlepp, Jörg: Maßnahmen zur Reduzierung von Unfällen mit Straßenbahnen, URL: <https://www.udv.de/resource/blob/79774/7347624f707513b528fed411867f5b89/37-massnahmen-zur-reduzierung-von-unfaellen-mit-strassenbahnen-data.pdf>, 2016, aufgerufen 28.09.2023

**Guerrieri, M. et al.: Smart Tramway Systems for Smart Cities (2022)**

Guerrieri, Marco; Parla, Giuseppe: Smart Tramway Systems for Smart Cities: A Deep Learning Application in ADAS Systems, in: International Journal of Intelligent Transportation Systems Research, 2022

**Guzhva, N. S. et al.: 3D Object Detection DNN (2022)**

Guzhva, N. S.; Prun, V. E.; Postnikov, V. V.; Lobanov, M. G.; Sadekov, R. N.; Sholomov, D. L.: Using 3D Object Detection DNN in an Autonomous Tram to Predict the Behaviour of Vehicles in the Road Scene, in: 2022 29th Saint Petersburg International Conference on Integrated Navigation Systems (ICINS), S. 1–6, 2022

**Hacker, L. et al.: Insufficiency-Driven DNN Error Detection (2023)**

Hacker, Lukas; Seewig, Jörg: Insufficiency-Driven DNN Error Detection in the Context of SOTIF on Traffic Sign Recognition Use Case, in: IEEE Open Journal of Intelligent Transportation Systems, Vol. 4, S. 58–70, 2023

**Hagemeyer, F. et al.: Automatisiertes Fahren auf der Schiene (2021)**

Hagemeyer, Friedrich; Preuß, Malte; Meyer Zu Hörste, Michael; Meirich, Christian; Flamm, Leander: Automatisiertes Fahren auf der Schiene: Technische und rechtliche Aspekte für die Praxis, essentials, Springer Fachmedien, 2021

**Häne, C. et al.: 3D perception using a multi-camera system (2017)**

Häne, Christian; Heng, Lionel; Lee, Gim Hee; Fraundorfer, Friedrich; Furgale, Paul; Sattler, Torsten; Pollefeys, Marc: 3D visual perception for self-driving cars using a multi-camera system: Calibration, mapping, localization, and obstacle detection, in: Image and Vision Computing, Vol. 68, S. 14–27, 2017

**Harris, M.: The Radical Scope of Tesla’s Data Hoard (2022)**

Harris, Mark: The Radical Scope of Tesla’s Data Hoard: Every Tesla is providing reams of sensitive data about its driver’s life, in: IEEE Spectrum, Vol. 59, S. 40–45, 2022

**Hasberg, C. et al.: SLAM Path-Constrained Motion (2012)**

Hasberg, C.; Hensel, S.; Stiller, C.: Simultaneous Localization and Mapping for Path-Constrained Motion, in: IEEE Transactions on Intelligent Transportation Systems, Vol. 13, S. 541–552, 2012

**Hasirlioglu, S. et al.: Simulating Rain Effects on Sensor Data (2020)**

Hasirlioglu, Sinan; Riener, Andreas: A General Approach for Simulating Rain Effects on Sensor Data in Real and Virtual Environments, in: IEEE Transactions on Intelligent Vehicles, Vol. 5, S. 426–438, 2020

**HEAG: Forschungs-Straßenbahn vorgestellt (2019)**

HEAG: Kooperationsprojekt stellt Forschungs-Straßenbahn zum automatisierten Fahren in der Digitalstadt Darmstadt vor - HEAG, URL: <https://www.heag.de/kooperationsprojekt-stellt-forschungs-strassenbahn-zum-automatisierten-fahren-in-der-digitalstadt-darmstadt-vor/>, 2019, aufgerufen 06. 09. 2023

**Heirich, O.: Localization of Trains and Mapping of Railway Tracks (2020)**

Heirich, Oliver: Localization of Trains and Mapping of Railway Tracks, Dissertation, Dissertation Technische Universität München, 2020

**Heirich, O. et al.: Magnetic Measurements for Train Localization (2017)**

Heirich, Oliver; Siebler, Benjamin; Hedberg, Erik: Study of Train-Side Passive Magnetic Measurements with Applications to Train Localization, in: Journal of Sensors, Vol. 2017, e8073982, 2017

**Hofmann, M.: Trams das Fahren lehren (2020)**

Hofmann, M.: Trams das Fahren lehren: auf dem Weg zur smarten, autonomen Straßenbahn, in: Nahverkehr, Vol. 38, 2020

**Hubmann, C. et al.: Automated Driving in Uncertain Environments (2018)**

Hubmann, Constantin; Schulz, Jens; Becker, Marvin; Althoff, Daniel; Stiller, Christoph: Automated Driving in Uncertain Environments: Planning With Interaction and Uncertain Maneuver Prediction, in: IEEE Transactions on Intelligent Vehicles, Vol. 3, S. 5–17, 2018

**ibeo: Whitelabel Datenblatt Scala B3.0 (2023)**

ibeo: Whitelabel Datenblatt Scala B3.0, 2023

**intellicar: Škoda präsentiert Antikollisionssystem (2022)**

intellicar: Škoda präsentiert eigenes Antikollisionssystem, URL: <https://intellicar.de/hardware-and-software/skoda-praesentiert-eigenes-antikollisionssystem/>, 2022, aufgerufen 11. 10. 2022

**ISO 21448: SOTIF (2022)**

ISO 21448: Road vehicles - Safety of the intended functionality, 2022

**ISO 23150: Datenkommunikation Sensoren und Datenfusionseinheit (2023)**

ISO 23150: Straßenfahrzeuge - Datenkommunikation zwischen Sensoren und der Datenfusionseinheit für automatisierte Fahrfunktionen - Logische Schnittstelle, 2023

**ISO 8855: Road vehicles Vocabulary (2011)**

ISO 8855: Road vehicles — Vehicle dynamics and road-holding ability — Vocabulary, 2011

**Jin, H. et al.: Cruise & Waymo win permits (2021)**

Jin, Hyunjoo; Lee, Jane; Dave, Paresh; Lee, Jane; Dave, Paresh: GM's Cruise, Alphabet's Waymo win permits to offer self-driving rides, in: Reuters. Technology, 2021

**Jin-Seo Park et al.: Concave Hull Algorithm (2012)**

Jin-Seo Park; Se-Jong Oh: A New Concave Hull Algorithm and Concaveness Measure for n-dimensional Datasets, in: Journal of Information Science and Engineering, Vol. 28, 2012

**Jocher, G. et al.: ultralytics/yolov5 (2022)**

Jocher, Glenn; Chaurasia, Ayush; Stoken, Alex; Borovec, Jirka; NanoCode012; Kwon, Yonghye; Michael, Kalen; TaoXie; Fang, Jiacong; Imyhxy; Lorna; Zeng, Yifu; Wong, Colin; V, Abhiram; Montes, Diego; Wang, Zhiqiang; Fati, Cristi; Nadar, Jebastin; Laughing; UnglvKitDe; Sonck, Victor; Tkianai; YxNONG; Skalski, Piotr; Hogan, Adam; Nair, Dhruv; Strobel, Max; Jain, Mrinal: ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation, in: Zenodo, 2022

**Joubert, N. et al.: Modern GNSS and Its Impact on AV (2020)**

Joubert, Niels; Reid, Tyler G. R.; Noble, Fergus: Developments in Modern GNSS and Its Impact on Autonomous Vehicle Architectures, in: 2020 IEEE Intelligent Vehicles Symposium (IV), S. 2029–2036, 2020

**KBA: PM erste Genehmigung zum automatisierten Fahren (2021)**

KBA: Kraftfahrt-Bundesamt - Pressemitteilungen - KBA erteilt erste Genehmigung zum automatisierten Fahren, URL: [https://www.kba.de/DE/Presse/Pressemitteilungen/Allgemein/2021/pm49\\_2021%20\\_erste\\_Genehmigung\\_automatisiertes\\_Fahren.html](https://www.kba.de/DE/Presse/Pressemitteilungen/Allgemein/2021/pm49_2021%20_erste_Genehmigung_automatisiertes_Fahren.html), 2021, aufgerufen 05.09.2023

**Koenig, A. et al.: Bridging the Gap (2017)**

Koenig, Alexander; Gutbrod, Michael; Hohmann, Sören; Ludwig, Julian: Bridging the Gap between Open Loop Tests and Statistical Validation for Highly Automated Driving, in: SAE International Journal of Transportation Safety, Vol. 5, S. 81–87, 2017

**Koenig, A. et al.: Passive HAD as a concept for Validation (2018)**

Koenig, Alexander; Witzlsperger, Kathrin; Leutwiler, Florin; Hohmann, Sören: Overview of HAD validation and passive HAD as a concept for validating highly automated cars, in: at - Automatisierungstechnik, Vol. 66, S. 132–145, 2018

**Korchev, D. et al.: Real-Time LIDAR Data Segmentation (2013)**

Korchev, Dmitriy; Cheng, Shinko; Owechko, Yuri; Kim, Kyungnam: On Real-Time LIDAR Data Segmentation and Classification, in: 2013

**Kortenkamp, D. et al.: Robotic Systems Architectures and Programming (2016)**

Kortenkamp, David; Simmons, Reid; Brugali, Davide: Robotic Systems Architectures and Programming, in: Siciliano, Bruno; Khatib, Oussama (Hrsg.): Springer Handbook of Robotics, Springer International Publishing, 2016

**Kröper, B. et al.: Fingerprint of Rails for Velocity Estimation and Localization (2020)**

Kröper, Bernd; Lauer, Martin; Spindler, Max: Using the Ferromagnetic Fingerprint of Rails for Velocity Estimation and absolute Localization of Railway Vehicles, in: 2020 European Navigation Conference (ENC), S. 1–10, 2020

**Kutilla, M. et al.: Automotive LiDAR performance verification in fog and rain (2018)**

Kutilla, M.; Pyykönen, P.; Holzhüter, H.; Colomb, M.; Duthon, P.: Automotive LiDAR performance verification in fog and rain, in: 2018 21st International Conference on Intelligent Transportation Systems (ITSC), S. 1695–1701, 2018

**Lambert, J. et al.: Performance Analysis of LiDARs (2020)**

Lambert, Jacob; Carballo, Alexander; Cano, Abraham Monrroy; Narksri, Patiphon; Wong, David; Takeuchi, Eijiro; Takeda, Kazuya: Performance Analysis of 10 Models of 3D LiDARs for Automated Driving, in: IEEE Access, Vol. 8, S. 131699–131722, 2020

**Lee, I.-S. et al.: Performance of RTK-GPS (2006)**

Lee, In-Su; Ge, Linlin: The performance of RTK-GPS for surveying under challenging environmental conditions, in: Earth, Planets and Space, Vol. 58, S. 515–522, 2006

**Leinhos, D. et al.: Sensorik als Voraussetzung für ATO (2022)**

Leinhos, Dirk; Flatt, Holger; Witte, Stefan: Sensorik als technische Voraussetzung für ATO-Funktionen, 2022

**Lensagon: Datenblatt BF10M19828S118 (2017)**

Lensagon: Datenblatt BF10M19828S118, 2017

**Li, N. et al.: Review on Solid-State LiDAR (2022)**

Li, Nanxi; Ho, Chong Pei; Xue, Jin; Lim, Leh Woon; Chen, Guanyu; Fu, Yuan Hsing; Lee, Lennon Yao Ting: A Progress Review on Solid-State LiDAR and Nanophotonics-Based LiDAR Sensors, in: Laser & Photonics Reviews, Vol. 16, S. 2100511, 2022

**Li, Y. et al.: What Happens for a ToF LiDAR in Fog? (2021)**

Li, You; Duthon, Pierre; Colomb, Michèle; Ibanez-Guzman, Javier: What Happens for a ToF LiDAR in Fog?, in: IEEE Transactions on Intelligent Transportation Systems, Vol. 22, S. 6670–6681, 2021

**Lin, T.-Y. et al.: Microsoft COCO (2015)**

Lin, Tsung-Yi; Maire, Michael; Belongie, Serge; Bourdev, Lubomir; Girshick, Ross; Hays, James; Perona, Pietro; Ramanan, Deva; Zitnick, C. Lawrence; Dollár, Piotr: Microsoft COCO: Common Objects in Context, URL: <http://arxiv.org/abs/1405.0312>, 2015, aufgerufen 24. 10. 2023

**Liu, R. et al.: High Definition Map for Automated Driving (2020)**

Liu, Rong; Wang, Jinling; Zhang, Bingqi: High Definition Map for Automated Driving: Overview and Analysis, in: Journal of Navigation, Vol. 73, S. 324–341, 2020

**Llatser, I. et al.: Cooperative Automated Driving Use Cases (2019)**

Llatser, Ignacio; Michalke, Thomas; Dolgov, Maxim; Wildschütte, Florian; Fuchs, Hendrik: Cooperative Automated Driving Use Cases for 5G V2X Communication, in: 2019 IEEE 2nd 5G World Forum (5GWF), S. 120–125, 2019

**Ma, X. et al.: Monocular 3D Object Detection (2019)**

Ma, Xinzhu; Wang, Zhihui; Li, Haojie; Zhang, Pengbo; Ouyang, Wanli; Fan, Xin: Accurate Monocular 3D Object Detection via Color-Embedded 3D Reconstruction for Autonomous Driving, in: S. 6851–6860, 2019

**Marti, E. et al.: Review of Sensor Technologies for Perception (2019)**

Marti, Enrique; de Miguel, Miguel Angel; Garcia, Fernando; Perez, Joshue: A Review of Sensor Technologies for Perception in Automated Driving, in: IEEE Intelligent Transportation Systems Magazine, Vol. 11, S. 94–108, 2019

**Maurer, M. et al.: Autonomes Fahren (2015)**

Maurer, Markus; Gerdes, J. Christian; Lenz, Barbara; Winner, Hermann: Autonomes Fahren, Springer, 2015

**Meng, Y. et al.: Simplified Map-Matching (2002)**

Meng, Yu; Chen, Wu; Li, Zhilin; Chen, Yongqi; Chao, Jason C.H.: A Simplified Map-Matching Algorithm for In-Vehicle Navigation Unit, in: Geographic Information Sciences, Vol. 8, S. 24–30, 2002

**Mihalj, T. et al.: Road Infrastructure Challenges Faced by Automated Driving (2022)**

Mihalj, Tomislav; Li, Hexuan; Babić, Dario; Lex, Cornelia; Jeudy, Mathieu; Zovak, Goran; Babić, Darko; Eichberger, Arno: Road Infrastructure Challenges Faced by Automated Driving: A Review, in: Applied Sciences, Vol. 12, S. 3477, 2022

**Morgan-Owen, G. J. et al.: Differential GPS positioning (1995)**

Morgan-Owen, G. J.; Johnston, G. T.: Differential GPS positioning, in: Electronics & Communication Engineering Journal, Vol. 7, S. 11–21, 1995

**Mori, K. et al.: Perception Relevance (2023)**

Mori, Ken; Storms, Kai; Peters, Steven: Conservative Estimation of Perception Relevance of Dynamic Objects for Safe Trajectories in Automotive Scenarios, in: 2023 IEEE International Conference on Mobility, Operations, Services and Technologies (MOST), S. 83–95, 2023

**Munkres, J.: Assignment and Transportation Problems (1957)**

Munkres, James: Algorithms for the Assignment and Transportation Problems, in: Journal of the Society for Industrial and Applied Mathematics, Vol. 5, S. 32–38, 1957

**Nagoya University et al.: Ray Ground Filter (2017)**

Nagoya University; Autoware Foundation: Autoware-Manuals/en/pdfs/ground\_filter.pdf at master · CPFL/Autoware-Manuals, URL: [https://github.com/CPFL/Autoware-Manuals/blob/master/en/pdfs/ground\\_filter.pdf](https://github.com/CPFL/Autoware-Manuals/blob/master/en/pdfs/ground_filter.pdf), 2017, aufgerufen 21. 10. 2023

**Nassi, B. et al.: Phantom of the ADAS (2020)**

Nassi, Ben; Mirsky, Yisroel; Nassi, Dudi; Ben-Netanel, Raz; Drokin, Oleg; Elovici, Yuval: Phantom of the ADAS: Securing Advanced Driver-Assistance Systems from Split-Second Phantom Attacks, in: Proceedings of the 2020 ACM SIGSAC Conference on Computer and Communications Security, S. 293–308, 2020

**Neurohr, C. et al.: Considerations around Scenario-Based Testing (2020)**

Neurohr, Christian; Westhofen, Lukas; Henning, Tabea; de Graaff, Thies; Möhlmann, Eike; Böde, Eckard: Fundamental Considerations around Scenario-Based Testing for Automated Driving, in: 2020 IEEE Intelligent Vehicles Symposium (IV), S. 121–127, 2020

**Niemann, J. et al.: VDV Innovationspapier Automatisierte Personenbeförderung (2021)**

Niemann, Jörg; Stegemann, Till; Scharl, Anna: Innovationspapier zur automatisierten und fahrerlosen Personenbeförderung (Rödl & Partner), 2021

**OTIV: ADAS OTIV.TWO (2023)**

OTIV: OTIV.TWO | Advanced Driver Assistance System for rail, URL: <https://www.otiv.ai/otiv-two>, 2023, aufgerufen 07. 12. 2023

**Palmer, A. W. et al.: The Autonomous Siemens Tram (2020)**

Palmer, Andrew W.; Sema, Albi; Martens, Wolfram; Rudolph, Peter; Waizenegger, Wolfgang: The Autonomous Siemens Tram, in: 2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC), S. 1–6, 2020

**Pech, D.: Trainingsstrategie für automatisiertes Fahren (2021)**

Pech, Daniel: Bachelor-Thesis: Entwicklung einer Trainingsstrategie für Maschinelles Lernen im Kontext von kamerabasiertem automatisierten Fahren, Dissertation, TU Darmstadt, 2021

**Pek, C. et al.: Online verification to prevent accidents (2020)**

Pek, Christian; Manzinger, Stefanie; Koschi, Markus; Althoff, Matthias: Using online verification to prevent autonomous vehicles from causing accidents, in: Nature Machine Intelligence, Vol. 2, S. 518–528, 2020

**Peleska, J. et al.: Standardisation Considerations for Autonomous Train Control (2022)**

Peleska, Jan; Haxthausen, Anne E.; Lecomte, Thierry: Standardisation Considerations for Autonomous Train Control, in: Margaria, Tiziana; Steffen, Bernhard (Hrsg.): Leveraging Applications of Formal Methods, Verification and Validation. Practice, Springer Nature Switzerland, 2022

**Photogrammetry & Robotics Bonn: Depth Clustering (2016)**

Photogrammetry & Robotics Bonn: Depth Clustering, URL: [https://github.com/PRBonn/depth\\_clustering](https://github.com/PRBonn/depth_clustering), 2016, aufgerufen 20. 10. 2023

**Rasmussen, J.: Skills, rules, and knowledge (1983)**

Rasmussen, Jens: Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models, in: IEEE Transactions on Systems, Man, and Cybernetics, Vol. SMC-13, S. 257–266, 1983

**Redmon, J. et al.: You Only Look Once (2016)**

Redmon, Joseph; Divvala, Santosh; Girshick, Ross; Farhadi, Ali: You Only Look Once: Unified, Real-Time Object Detection, in: S. 779–788, 2016

**Ristić-Durrant, D. et al.: Vision-Based On-Board Obstacle Detection (2021)**

Ristić-Durrant, Danijela; Franke, Marten; Michels, Kai: A Review of Vision-Based On-Board Obstacle Detection and Distance Estimation in Railways, in: *Sensors*, Vol. 21, S. 3452, 2021

**Ruppert, T. et al.: Map-Based Path and Pose for Trams (2021)**

Ruppert, Timm; Guba, Christian; Ruks, Benjamin; Winner, Hermann: Map-Based Path and Pose Information for Automated and Assisted Driving of Trams, in: *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, S. 553–558, 2021

**SAE J3016: Taxonomy and Definitions (2021)**

SAE J3016: Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles, 2021

**Sayyah, K. et al.: Fully Integrated FMCW LiDAR Engine (2022)**

Sayyah, Keyvan; Sarkissian, Raymond; Patterson, Pamela; Huang, Biqin; Efimov, Oleg; Kim, Danny; Elliott, Ken; Yang, Louis; Hammon, David: Fully Integrated FMCW LiDAR Optical Engine on a Single Silicon Chip, in: *Journal of Lightwave Technology*, Vol. 40, S. 2763–2772, 2022

**Schnieder, L.: Automatisierung im schienengebundenen Nahverkehr (2019)**

Schnieder, Lars: *Automatisierung im schienengebundenen Nahverkehr: Funktionen und Nutzen von Communication-Based Train Control (CBTC)*, Springer eBook Collection, Springer Vieweg, 2019

**Schnieder, L.: Communications-Based Train Control (CBTC) (2021)**

Schnieder, Lars: *Communications-Based Train Control (CBTC): Komponenten, Funktionen und Betrieb*, Springer, 2021

**Schwall, M. et al.: Waymo Safety Performance Data (2020)**

Schwall, Matthew; Daniel, Tom; Victor, Trent; Favaro, Francesca; Hohnhold, Henning: *Waymo Public Road Safety Performance Data*, URL: <http://arxiv.org/abs/2011.00038>, 2020, aufgerufen 05. 09. 2023

**Siemens: Autonomous trams on the rail and in the depot (2023)**

Siemens: *Autonomous trams on the rail and in the depot*, URL: <https://www.mobility.siemens.com/global/en/portfolio/rolling-stock/trams-and-light-rail/autonomous-tram.html>, 2023, aufgerufen 07. 12. 2023

**Stolte, T. et al.: Safety goals and functional safety requirements (2016)**

Stolte, Torben; Bagschik, Gerrit; Maurer, Markus: Safety goals and functional safety requirements for actuation systems of automated vehicles, in: *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, S. 2191–2198, 2016

**SWARCO: FUTURLED 6 (2023)**

SWARCO: *FUTURLED 6 - 230V AC* | SWARCO, URL: <https://www.swarco.com/de/produkte/signalgeber-und-zubehoer/led-module/futurled-6-230v-ac>, 2023, aufgerufen 07. 11. 2023

**Swift Navigation: Duro Product Summary (2021)**

Swift Navigation: Duro Product Summary, URL: [https://www.swiftnav.com/sites/default/files/duro\\_product\\_summary.pdf](https://www.swiftnav.com/sites/default/files/duro_product_summary.pdf), 2021

**Tagiew, R. et al.: Onboard Sensor Systems for Automatic Train Operation (2022)**

Tagiew, Rustam; Leinhos, Dirk; von der Haar, Henrik; Klotz, Christian; Sprute, Dennis; Ziehn, Jens; Schmelter, Andreas; Witte, Stefan; Klasek, Pavel: Onboard Sensor Systems for Automatic Train Operation, in: Dependable Computing – EDCC 2022 Workshops, S. 139–150, 2022

**Tas, O. S. et al.: Functional system architectures (2016)**

Tas, Omer Sahin; Kuhnt, Florian; Zollner, J. Marius; Stiller, Christoph: Functional system architectures towards fully automated driving, in: 2016 IEEE Intelligent Vehicles Symposium (IV), S. 304–309, 2016

**Thales: AI for the autonomous trams (2019)**

Thales: Artificial intelligence for the autonomous trams, URL: <https://www.thalesgroup.com/en/germany/news/artificial-intelligence-autonomous-trams>, 2019, aufgerufen 07. 12. 2023

**Tilly, R. et al.: Multisensordatensatz (2023)**

Tilly, Roman; Neumaier, Philipp; Schwalbe, Karsten; Klasek, Pavel; Tagiew, Rustam; Denzler, Patrick; Klockau, Tobias; Köppel, Köppel: Offener Multisensordatensatz für die Entwicklung der Umfeldwahrnehmung beim vollautomatischen Fahren, 2023

**Triess, L. T. et al.: A Survey on Deep Domain Adaptation for LiDAR Perception (2021)**

Triess, Larissa T.; Dreissig, Mariella; Rist, Christoph B.; Marius Zöllner, J.: A Survey on Deep Domain Adaptation for LiDAR Perception, in: 2021 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops), S. 350–357, 2021

**Trimble Navigation: Produktbroschüre: Trimble GEDO Systeme (2023)**

Trimble Navigation: Trimble GEDO Systeme - Lösungen für die Gleisvermessung, 2023

**Ulbrich, S. et al.: Defining the Terms Scene, Situation, and Scenario (2015)**

Ulbrich, Simon; Menzel, Till; Reschka, Andreas; Schuldt, Fabian; Maurer, Markus: Defining and Substantiating the Terms Scene, Situation, and Scenario for Automated Driving, in: 2015 IEEE 18th International Conference on Intelligent Transportation Systems, S. 982–988, 2015

**Ulbrich, S. et al.: Definition der Begriffe Szene, Situation und Szenar (2015)**

Ulbrich, Simon; Menzel, Till; Reschka, Andreas; Schuldt, Fabian; Maurer, Markus: Definition der Begriffe Szene, Situation und Szenario für das automatisierte Fahren, in: 2015

**VDV: Dienstanweisungen für den Fahrdienst mit Straßenbahnen (2002)**

VDV: Dienstanweisungen für den Fahrdienst mit Straßenbahnen, 2002

**VDV: Personalumfrage im ÖV (2023)**

VDV: Personalumfrage im ÖV, URL: <https://www.vdv.de/vdv-personalumfrage-im-oev.aspx>, 2023, aufgerufen 02. 01. 2024

**VDV: Technische Regeln Bremsen (2008)**

VDV: Technische Regeln für die Bemessung und Prüfung der Bremsen von Fahrzeugen nach der Verordnung über den Bau und Betrieb der Straßenbahnen (BOStrab), 2008

**Velodyne: Datenblatt Ultra Puck VLP-32C (2017)**

Velodyne: Datenblatt Ultra Puck VLP-32C, 2017

**Vires Hexagon: VTD for Railway Industry (2023)**

Vires Hexagon: Railway Industry Virtual Test Drive, URL: <https://vires.mscsoftware.com/industry/railway/>, 2023, aufgerufen 16. 09. 2023

**Vosselman, G. et al.: Airborne and terrestrial laser scanning (2010)**

Vosselman, G.; Maas, H. G.: Airborne and terrestrial laser scanning, CRC Press (Taylor & Francis), 2010

**Wachenfeld, W. et al.: VAAFO - Runtime Validation Method (2015)**

Wachenfeld, W.; Winner, H.: Virtual Assessment of Automation in Field Operation – A New Runtime Validation Method, in: 2015

**Wang, C. et al.: “Watch out!” (2020)**

Wang, Chao; Krüger, Matti; Wiebel-Herboth, Christiane B.: “Watch out!”: Prediction-Level Intervention for Automated Driving, in: 12th International Conference on Automotive User Interfaces and Interactive Vehicular Applications, S. 169–180, 2020

**Wang, C.: Silent Testing for Validation (2021)**

Wang, Cheng: Silent Testing for Safety Validation of Automated Driving in Field Operation, Dissertation, Technische Universität, 2021

**Wang, C. et al.: Challenges of Validation and Identification Scenarios (2019)**

Wang, Cheng; Winner, Hermann: Overcoming Challenges of Validation Automated Driving and Identification of Critical Scenarios, in: 2019 IEEE Intelligent Transportation Systems Conference (ITSC), S. 2639–2644, 2019

**Wang, C. et al.: Improved DBSCAN Method for LiDAR Data + (2019)**

Wang, Chunxiao; Ji, Min; Wang, Jian; Wen, Wei; Li, Ting; Sun, Yong: An Improved DBSCAN Method for LiDAR Data Segmentation with Automatic Eps Estimation, in: Sensors, Vol. 19, S. 172, 2019

**Wang, Z. et al.: Assessment of architectures for ATO (2022)**

Wang, Ziyulong; Quaglietta, Egidio; Bartholomeus, Maarten G. P.; Goverde, Rob M. P.: Assessment of architectures for Automatic Train Operation driving functions, in: Journal of Rail Transport Planning & Management, Vol. 24, S. 100352, 2022

**Weichselbaum, J. et al.: Accurate 3D-vision-based obstacle detection for an autonomous train (2013)**

Weichselbaum, Johann; Zinner, Christian; Gebauer, Oliver; Pree, Wolfgang: Accurate 3D-vision-based obstacle detection for an autonomous train, in: Computers in Industry, Vol. 64, S. 1209–1220, 2013

**Weng, J. et al.: Camera calibration with distortion models and accuracy evaluation (1992)**

Weng, Juyang; Cohen, Paul; Herniou, Marc et al.: Camera calibration with distortion models and accuracy evaluation, in: IEEE Transactions on pattern analysis and machine intelligence, Vol. 14, S. 965–980, 1992

**Westhofen, L. et al.: Criticality Metrics for Automated Driving (2023)**

Westhofen, Lukas; Neurohr, Christian; Koopmann, Tjark; Butz, Martin; Schütt, Barbara; Utesch, Fabian; Neurohr, Birte; Gutenkunst, Christian; Böde, Eckard: Criticality Metrics for Automated Driving: A Review and Suitability Analysis of the State of the Art, in: Archives of Computational Methods in Engineering, Vol. 30, S. 1–35, 2023

**Wiederer, J. et al.: Anomaly Detection (2022)**

Wiederer, Julian; Bouazizi, Arij; Troina, Marco; Kressel, Ulrich; Belagiannis, Vasileios: Anomaly Detection in Multi-Agent Trajectories for Automated Driving, in: Proceedings of the 5th Conference on Robot Learning, S. 1223–1233, 2022

**Winner, H. et al.: Handbuch Fahrerassistenzsysteme (2015)**

Winner, Hermann; Hakuli, Stephan; Lotz, Felix; Singer, Christina: Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort, Springer Fachmedien, 2015

**Wu, Z. et al.: Hybrid LED traffic light detection using high-speed camera (2016)**

Wu, Zhipeng; Watanabe, Yoshihiro; Ishikawa, Masatoshi: Hybrid LED traffic light detection using high-speed camera, in: 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), S. 1235–1241, 2016

**Xiao, Y. et al.: A review of object detection based on deep learning (2020)**

Xiao, Youzi; Tian, Zhiqiang; Yu, Jiachen; Zhang, Yinshu; Liu, Shuai; Du, Shaoyi; Lan, Xuguang: A review of object detection based on deep learning, in: Multimedia Tools and Applications, Vol. 79, S. 23729–23791, 2020

**Xie, D. et al.: Obstacle detection and tracking based on LiDAR (2019)**

Xie, Desheng; Xu, Youchun; Wang, Rendong: Obstacle detection and tracking method for autonomous vehicle based on three-dimensional LiDAR, in: International Journal of Advanced Robotic Systems, Vol. 16, S. 1729881419831587, 2019

**Yabuuchi, K. et al.: Traffic Light Detection with Frequency Patterns (2020)**

Yabuuchi, Kento; Hirano, Masahiro; Senoo, Taku; Kishi, Norimasa; Ishikawa, Masatoshi: Real-Time Traffic Light Detection with Frequency Patterns Using a High-Speed Camera, in: Sensors, Vol. 20, S. 4035, 2020

**Yang, B. et al.: Crossing or Not? (2022)**

Yang, Biao; Zhan, Weiqin; Wang, Pin; Chan, Chingyao; Cai, Yingfeng; Wang, Nan: Crossing or Not? Context-Based Recognition of Pedestrian Crossing Intention in the Urban Environment, in: IEEE Transactions on Intelligent Transportation Systems, Vol. 23, S. 5338–5349, 2022

**Yeong, D. J. et al.: Sensor and Sensor Fusion Technology in Autonomous Vehicles (2021)**

Yeong, De Jong; Velasco-Hernandez, Gustavo; Barry, John; Walsh, Joseph: Sensor and Sensor Fusion Technology in Autonomous Vehicles: A Review, in: Sensors, Vol. 21, S. 2140, 2021

**Zhang, L. et al.: Towards Unsupervised Object Detection from LiDAR Point Clouds (2023)**

Zhang, Lunjun; Yang, Anqi Joyce; Xiong, Yuwen; Casas, Sergio; Yang, Bin; Ren, Mengye; Urtasun, Raquel: Towards Unsupervised Object Detection from LiDAR Point Clouds, in: 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), S. 9317–9328, 2023

**Zhang, Q. et al.: Obstacle Detection Method for the Train (2023)**

Zhang, Qiang; Yan, Fei; Song, Weina; Wang, Rui; Li, Gen: Automatic Obstacle Detection Method for the Train Based on Deep Learning, in: Sustainability, Vol. 15, S. 1184, 2023

**Zhao, Y. et al.: Survey of Traditional Point Cloud Clustering Methods (2021)**

Zhao, Yiming; Zhang, Xiao; Huang, Xinming: A Technical Survey and Evaluation of Traditional Point Cloud Clustering Methods for LiDAR Panoptic Segmentation, in: S. 2464–2473, 2021

**Zhao, Z.-Q. et al.: Object Detection With Deep Learning (2019)**

Zhao, Zhong-Qiu; Zheng, Peng; Xu, Shou-Tao; Wu, Xindong: Object Detection With Deep Learning: A Review, in: IEEE Transactions on Neural Networks and Learning Systems, Vol. 30, S. 3212–3232, 2019

**Zheng, L. et al.: TJ4DRadSet (2022)**

Zheng, Lianqing; Ma, Zhixiong; Zhu, Xichan; Tan, Bin; Li, Sen; Long, Kai; Sun, Weiqi; Chen, Sihan; Zhang, Lu; Wan, Mengyue; Huang, Libo; Bai, Jie: TJ4DRadSet: A 4D Radar Dataset for Autonomous Driving, in: 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC), S. 493–498, 2022

**Zhu, C. et al.: Influence of haze on FMCW laser (2019)**

Zhu, Changming; Du, Xiaoping; Song, Yishuo; Chen, Peng: Influence of haze on pulse and FMCW laser ranging accuracy, in: 14th National Conference on Laser Technology and Optoelectronics (LTO 2019), Bd. 11170, S. 425–431, 2019

**Ziegler, J. et al.: Making Bertha Drive (2014)**

Ziegler, Julius; Bender, Philipp; Schreiber, Markus; Lategahn, Henning; Strauss, Tobias; Stiller, Christoph; Dang, Thao; Franke, Uwe; Appenrodt, Nils; Keller, Christoph G.; Kaus, Eberhard; Herrtwich, Ralf G.; Rabe, Clemens; Pfeiffer, David; Lindner, Frank; Stein, Fridtjof; Erbs, Friedrich; Enzweiler, Markus; Knöppel, Carsten; Hipp, Jochen; Haueis, Martin; Trepte, Maximilian; Brenk, Carsten; Tamke, Andreas; Ghanaat, Mohammad; Braun, Markus; Joos, Armin; Fritz, Hans; Mock, Horst; Hein, Martin; Zeeb, Eberhard: Making Bertha Drive - An Autonomous Journey on a Historic Route, in: IEEE Intelligent Transportation Systems Magazine, Vol. 6, S. 8–20, 2014

**Zofka, M. R. et al.: Testing and validating high level components for automated driving (2016)**

Zofka, Marc René; Klemm, Sebastian; Kuhnt, Florian; Schamm, Thomas; Zöllner, J. Marius: Testing and validating high level components for automated driving: simulation framework for traffic scenarios, in: 2016 IEEE Intelligent Vehicles Symposium (IV), S. 144–150, 2016

## Eigene Publikationen

**Ruppert, Timm;** Guba, Christian; Ruks, Benjamin; Winner, Hermann: Map-Based Path and Pose Information for Automated and Assisted Driving of Trams, IEEE International Intelligent Transportation Systems Conference (ITSC), 19.–22.September 2021, Indianapolis USA, doi 10.1109/ITSC48978.2021.9564773, 2021.

Amersbach, Christian; **Ruppert, Timm;** Hebgen, Niclas; Winner, Hermann (2021): Macroscopic Safety Requirements for Highly Automated Driving in Urban Environments, Graz Symposium Virtual Vehicle (GSVF), Graz, 01.–02. September 2020, Graz Österreich, doi: 10.26083/tuprints-00013470, 2020.

**Ruppert, Timm;** Patrick Pintscher, Patrick Eschküdt, Matthias Clemenz (2021): Die MAAS-Bahn zur Erforschung der Automatisierung und Teleoperation von Straßenbahnen, ÖPNV-Innovationskongress, 09. Juni 2021, Stuttgart/Digital, **Mündlicher Vortrag**.

**Ruppert, Timm;** Patrick Eschküdt (2022): Teleoperation Als Ergänzung der Automatisierung von Straßenbahnen, Fachtagung Der automatisierte Betriebshof, 12.–13. Mai 2022, Potsdam, **Mündlicher Vortrag**.

## Betreute Thesen

**Claaßen, Christian:** Entwicklung einer bidirektionalen Schnittstelle zum Lesen und Schreiben von Fahrzeugsignalen für automatisiertes Fahren.

Bachelor-Thesis Nr. 1323/18

**Hebgen, Niclas:** Definition makroskopischer Sicherheitsanforderungen für automatisiertes Fahren in der Stadt.

Master-Thesis Nr. 748/19

**Guba, Christian:** Entwicklung eines Lokalisierungsmoduls für automatisiertes Fahren spurgebundener Fahrzeuge

Master-Thesis Nr. 1631/20

**He, Daniel:** Entwurf einer Objektdetektion mittels Fusion von zwei Lidar Sensoren für automatisiertes Fahren

Master-Thesis Nr. 801/20

**Pech, Daniel:** Entwicklung einer Trainingsstrategie für Maschinelles Lernen im Kontext von kamerabasiertem automatisierten Fahren

Bachelor-Thesis Nr. 1377/20

**Reichert, Jonas:** Entwurf und Umsetzung einer Verhaltensplanung für automatisiertes Fahren

Bachelor-Thesis Nr. 1378/20

**Mathes, Leonie:** Entwurf und Anwendung einer Methodik zur Kalibration von Umfeldsensoren für automatisiertes Fahren

Bachelor-Thesis Nr. 1355/20

**Kranz, Tim:** Umsetzung und Evaluierung eines Stereokamera-Softwaremoduls für automatisiertes Fahren

Bachelor-Thesis Nr. 1356/20

**Sura, Christopher:** Development of a Light Signal Detection in the Application within Automated Driving

Master-Thesis Nr. 1393/20

**Ahmadi, Josef:** Potentialanalyse lidarbasierter Umfelderkennung für automatisiertes Fahren von Straßenbahnen

Master-Thesis Nr. 775/20

**Jing, Yuhao:** Analyse zur Umfeldperzeption mittels Fisheye-Kameras für automatisiertes Fahren von Straßenbahnen

Master-Thesis Nr. 782/20

**Mori, Ken:** Potential Analysis of Camera Based Environment Perception for Automated Driving of Trams

Master-Thesis Nr. 773/20

**Jonas, Philipp:** Maschinelle Perzeption von Lichtsignalanlagen und Verkehrszeichen für automatisiertes Fahren

Master-Thesis Nr. 801/20

**Laubach, Lorenz:** Sensorfusion und Entwicklung einer virtuellen Umfeld-Repräsentation für automatisiertes Fahren

Master-Thesis Nr. 802/20

**Prott, Florian:** Kollisionsvermeidung durch Zustandsvorhersage von dynamischen Objekten für automatisiertes Fahren

Master-Thesis Nr. 811/21