



Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

Konsortialbericht

Verbundprojekt:

AutoConstruct – Echtzeitfähige Umfelderkennung von Baustellen mittels serientauglicher und kostenoptimierter Kamera-Sensorik für das hoch- und vollautomatisierte Fahren

Förderkennzeichen:

Continental: 19A16011A **bplus:** 19A16011C **TÜV NORD:** 19A16011E

Fraunhofer IAIS: 19A16011D

CMORE 19A16011B

Inhaltsverzeichnis

1.	Kurzdarstellung.....	5
1.1	Aufgabenstellung.....	5
1.2	Voraussetzungen	8
1.3	Planung und Ablauf des Vorhabens	10
1.3.1	Übersicht Arbeitsteilung.....	14
1.3.2	Planung und Ablauf des Vorhabens	15
1.3.3	Arbeitspaketplanung	16
1.4	Wissenschaftlicher und technischer Stand	18
1.5	Zusammenarbeit mit anderen Stellen.....	22
2.	Eingehende Darstellung	24
2.1	Verwendung der Zuwendung.....	24
2.2	Notwendigkeit und Angemessenheit der geleisteten Arbeit.....	118
2.3	Nutzen/Verwertbarkeit des Ergebnisses.....	119
2.4	Bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen.....	123
2.5	Veröffentlichungen des Ergebnisses	125
	Literaturverzeichnis.....	127

Abbildungsverzeichnis

Abbildung 1: Baustellenbereich (Fotoquelle ADAC) und komplexe Verkehrsschilder.....	8
Abbildung 2: Technology Readiness Level	9
Abbildung 3: Entwicklungs- und Validierungsprozess für neue Funktionen und Algorithmen.....	12
Abbildung 4: Übersicht Arbeitsteilung	14
Abbildung 5: Projektplanung.....	17
Abbildung 6: Vernetzungskonzept der Ausbaustufe 1.....	28
Abbildung 7: Vernetzungskonzept der Ausbaustufe 2.....	29
Abbildung 8: Konzept zur Bestimmung des Bitfehlerverhältnisses	36
Abbildung 9: Konzept zur Bestimmung des Bitfehlerverhältnis unter EMI.....	37
Abbildung 10: Schichtenmodell Kommunikationsarchitektur am Beispiel Ethernet.....	38
Abbildung 11: TNM Layer-1 Test Setup.....	40
Abbildung 12: Test Architektur TNM Interoperabilitäts-Tester	42
Abbildung 13: TNM Protocol Layer Test Setup	43
Abbildung 14: Blockschaltbild Powermanagement	45
Abbildung 15: Schaltung Powermanagement.....	46
Abbildung 16: Versuchsträger Ausbaustufe 1	47
Abbildung 17: Inbetriebnahme des Versuchsträgers / Ausbaustufe 1	47
Abbildung 18: Versuchsträger AutoConstruct auf der Continental Kalibrierfläche in Memmingen	48
Abbildung 19: Fahrzeugaufbau VW Passat B8 Variant- Ausbaustufe 1	48
Abbildung 20: Änderungen – Ausbaustufe 2 Stand zum 31.12.2018.....	49
Abbildung 21: Halterung Long Range Kamera	50
Abbildung 22: Übersicht Kameras Stand zum 31.12.2018	50
Abbildung 23: Änderungen – Ausbaustufe 2 Stand zum 30.06.2019.....	51
Abbildung 24: Übersicht Kameras Stand zum 30.06.2019	52
Abbildung 25: Erste Screening-Fahrt.....	53
Abbildung 26: Online-Baustelleninformationen	54
Abbildung 27: Routenberechnung nach dem Ansatz "Destination"	55
Abbildung 28: Routenberechnung nach dem Ansatz „Distance“	55
Abbildung 29: mobile Ansicht des Systems.....	56
Abbildung 30: Übersicht - Basis Routenplaner.....	57
Abbildung 31: Filtern von bereits gefahrenen Baustellen.....	58
Abbildung 32: Fahrtrichtung der Baustellen wird über farbige Flags erkennbar.....	58
Abbildung 33: Nicht gefahrene Baustellen.....	59
Abbildung 34: Gefahrene Baustellen	59
Abbildung 35: Auswertung der eingefahrenen Daten	59
Abbildung 36: Pre-Tagging mit CMORE-PODBOX.....	60
Abbildung 37: Annotationsprozess	61
Abbildung 38: Verwechslungsmatrix Baustellenverkehrszeichen	63
Abbildung 39: Verschwenkungstafeln.....	63
Abbildung 40: Korrekt klassifizierte Baustellenschilder mit enganliegenden Bounding-Boxen	64
Abbildung 41: Darstellung automatisches Online-Tagging	65
Abbildung 42: Baustellenverkehrszeichen und Zusatzzeichen	68
Abbildung 43: Komplexe Hinweisschilder	69
Abbildung 44: Detektion eines komplexen Hinweisschildes.....	70
Abbildung 45: Zweistufige Detektion eines Spurführungszeichens.....	71
Abbildung 46: Schematische Darstellung der CNN-Architektur.....	73

Abbildung 47: Schematische Darstellung der CNN-Architektur zur Detektion der Spurführungszeichen	74
Abbildung 48: Schematische Darstellung der Pipeline zur Erkennung der Spurführungszeichen	75
Abbildung 49: Schematische Darstellung der Pfeilendendetektion mittels eigens entworfenen Filters	75
Abbildung 50: Beispielhafte Darstellung der Dataaugmentation der Pfeildetektion	76
Abbildung 51: Darstellung der Pfeilklassifikation.....	77
Abbildung 52: Schematische Darstellung des Voting-Prozesses von Kantenpixeln der Formdetektoren	79
Abbildung 53: Erkennungsergebnis der Overhead-Verkehrszeichen	80
Abbildung 54: Erkennungsergebnis der Bakenerkennung	81
Abbildung 55: Barken und Pylonen	83
Abbildung 56: Detektionen von Baken auf Autobahn (grün).....	84
Abbildung 57: Barken und Pylonen	85
Abbildung 58: Baustellenankündigungszeichen.....	85
Abbildung 59: mobiles Verkehrszeichen	85
Abbildung 60: Yolo-V3 Ergebnisse.....	86
Abbildung 61: Detektierte Baken, Pylonen und ein Baustellenschild mit dem SSD-MobilNet Detektor, dargestellt mit der implementierten Visualisierung	87
Abbildung 62: SSD-MobilNet Ergebnisse.....	87
Abbildung 63: Verkehrszeichen Extraktion MobileNet	88
Abbildung 64: Dataset RetinaNet	89
Abbildung 65: Datenverteilung RetinaNet	90
Abbildung 66: Ergebnisse RetinaNet	91
Abbildung 67: Physical System	92
Abbildung 68: Systemmatrix	93
Abbildung 69: Evolution Fahrbahnerkennung	94
Abbildung 70: Beispiel semantische Segmentierung zur Spurerkennung, Juni 2019	95
Abbildung 71: Confusion Matrix der vollständigen semantischen Segmentierung, Juni 2019.....	96
Abbildung 72: Mean IoU Werte der vollständigen semantischen Segmentierung, Juni 2019	97
Abbildung 73: Fahrbahnmarkierungserkennung Gelb und Weiß	98
Abbildung 74: Feldtauglicher Kalibrierungsansätze	106
Abbildung 75: Beispielhafte Baustellenszene	108
Abbildung 76: Systematisierung von Konsequenzen, wenn Zeichen übersehen werden	110
Abbildung 77: PODBOX-Oberfläche zum Online Tagging.....	110
Abbildung 78: Erklärung Winkel.....	111
Abbildung 79: Erklärung Abstand.....	111
Abbildung 80: Ansicht Fahrzeug von hinten Normalzustand und in Schräglage	112
Abbildung 81: Analyseprozess für Baustellenobjekte.....	114
Abbildung 82: Intersection over Union	115
Abbildung 83: Prozess der Datenanalyse und GT-Bereinigung für Baustellenobjekte	116
Abbildung 84: Prozess der Datenanalyse für Spurmarkierungen	117
Abbildung 85: Autonomes Fahren: Die Infografik des VDA gibt einen Überblick [38].....	119

Tabellenverzeichnis

Tabelle 1: Ressourcenplanung.....	15
Tabelle 2: Aufteilung des Projektaufwands.....	24
Tabelle 3: Ergebnis der Experimente zur Parametrisierung des CNN-Trainings.....	73
Tabelle 4: Übersicht der Parameter zum Training des CNNs zur Klassifikation der Overhead-Verkehrszeichen.....	79
Tabelle 5: Übersicht der Parameter zum Training des CNNs zur Klassifikation der Baken.....	81
Tabelle 6: Prozentuale Abweichung zwischen x1 und x2.....	113

1. Kurzdarstellung

Im Projekt AutoConstruct wurde unter Verwendung serientauglicher und kostenoptimierter Sensorik (Kamera) eine integrierte Anwendung zur echtzeitfähigen Umfelderkennung von Baustellen für das hoch- und vollautomatisierte Fahren entwickelt und erprobt.

Dazu wurden zum einen innovative Methoden zur Sensordatenanalyse erforscht und echtzeitfähige Algorithmen zur Erkennung von komplexen Baustellenschildern, -begrenzungen (z. B. Baken) sowie für die robuste und präzise Erkennung von überlagerten Fahrbahnmarkierungen realisiert.

Zum anderen wurden die Algorithmen in eine hoch performante und sichere Fahrzeug IT-Umgebung integriert, die es ermöglichte, in Echtzeit große Datenmengen zeitsynchron zu verarbeiten, aufzuzeichnen und durch algorithmenbasierte Labelingverfahren zu annotieren.

Hierzu wurden breitbandige Kommunikationssysteme in einer emissionsreichen Umgebung (Fahrzeug) integriert und für hochautomatisiertes Fahren benötigte Vernetzungsanforderung erprobt und optimiert.

1.1 Aufgabenstellung

Um beim hochautomatisierten Fahren eine evtl. Fahrerübergabe vor Beginn eines Baustellenbereiches einzuleiten, ist die Erkennung von Baustellen notwendig. Hierfür sollten sowohl Baustellenverkehrszeichen selbst als auch die Zusatzzeichen, insbesondere der Abstand zur Baustelle, überlagerte Fahrbahnmarkierungen, Warnhinweise sowie Baken und Pylonen erkannt und verarbeitet werden.

Ziel des Projektes war es, eine echtzeitfähige Umfelderkennung für Baustellen mittels serientauglicher und kostengünstiger Kamera-Sensortechnologien in einer hoch performanten Systemarchitektur, die zeitsynchrone Echtzeitkommunikation von mehrkanaligen Sensordaten ermöglicht, darzustellen. Dies sollte ohne den Einsatz kostenintensiver und aufwändiger Technologien, wie z. B. mechanisch beweglichen Laserscannern, stattfinden. Ebenfalls war die Weiterentwicklung und Integration einer präziseren Spurführung mithilfe von Nahfeld-Kameras geplant.

Sensordatenanalyse

Der algorithmische Kern des Projektes lag in der eigentlichen kamerabasierten Sensordatenanalyse. Hierzu waren leistungsfähige Bilderkennungsverfahren, die die Erkennung von komplexen Schildern und überlagerten Fahrspurmarkierungen sowie eine semantische Auswertung realisieren, zu implementieren.

Notwendige Voraussetzung für diese F&E Arbeiten war die Bereitstellung von umfangreichen annotierten Trainings- und Testdaten von Baustellen. Daher waren Lösungen zu einer effizienten Aufnahme und Annotation (Labeling) von Videoaufnahmen in Baustellen eine notwendige Voraussetzung für den Projekterfolg. Dies wurde dadurch verstärkt, dass moderne Sensordatenanalyse auf statistischen und lernenden Verfahren, wie beispielsweise Deep Learning basieren und ihre volle Leistungsfähigkeit erst entfalten, wenn umfangreich annotierte Referenzdaten vorliegen. Daher war eine effiziente Labelingumgebung der Schlüssel für die Verbesserung der Sensordatenanalyse. Darüber hinaus mussten die Kameradaten zeitsynchron und in Echtzeit im Fahrzeug übertragen und zusammengeführt werden. Dafür wurden eine hoch performante Systemarchitektur und Vernetzung der Komponenten in dem Projekt adressiert. Nachfolgend wurden diese drei Innovationsfelder, die auch durch entsprechende Arbeitspakete abgebildet wurden, dargestellt.

Systemarchitektur und Vernetzung

In bereits bestehenden Projekten wurden auch im Zuge der seriennahen Vorentwicklung meist speziell entwickelte individuelle Plattformen eingesetzt. Für zukünftige Architekturen ist eine der Schlüsselinnovationen der Einsatz neuer Vernetzungstechnologien für smarte Sensorik, sowie die hochgenaue Zeitsynchronisierung der einzelnen Sensoren und Aktoren mit einem zentralen Domaincontroller. Die Bereitstellung einer einheitlichen Zeitbasis als „Workingclock“ erlaubt erst die Datenfusion einzelner sensorischer Elemente. Hier durch entsteht die Möglichkeit, komplexe digitale dynamische Umfeldmodelle (Environment Fusion) im Sinne eines elektronischen Horizonts zu erzeugen.

Im Rahmen des Projektes wurde prototypisch eine entsprechende Plattform im Fahrzeug etabliert. Richtungsweisend für die Zukunft ist, die Möglichkeit der Reduzierung der Innovationszyklen durch den Wegfall der Migrationsaufwände bestehender PC-basierter Funktionsentwicklung, auf eine technologisch abweichende Embedded Plattform. Ein Downscale der Plattform auf die tatsächlichen Bedürfnisse im Fahrzeug versteht sich als obligatorisch. Als Zielstellung für die Zukunft leitet sich ein „ECU as a Software Component“ Ansatz ab. Die Möglichkeiten des Hypervising ebeneden hier die technologische Implementierung sicherer Fahrzeugcontroller-Architekturen.

Stand der Technik sind intelligente ADAS Systeme, die dezentral Längs- und Querobjekte detektieren und teilweise mit anderen dezentralen Systemen interagieren. Entscheidungen werden häufig in einem dezentralen System getroffen. Die bestehenden Vernetzungsarchitekturen erlauben es den erkannten Objekten zu kommunizieren. Eine zentrale Berechnung auf Rohdatenbasis ist auf Grund der Limitierung der Rechenperformance und der Übertragungsbandbreite nicht gegeben. Die Erweiterung um zusätzliche Funktionen wird durch einen zentralen Ansatz mit zentral höherer Rechenleistung erleichtert. Die Systemumgebung dezentraler Systeme kann bei verschiedenen Lieferanten in einem Technologieträger sehr heterogen sein. Eine homogen logische und physikalische Struktur erlaubt eine deutlich leichtere Realisierung der zukünftigen Anforderungen in Bezug auf Safety

und Security als Basis für autonomes Fahren bei gleichzeitig hoher Modularität und sich kommunikativ öffnenden Systemen.

IT-Architektur und Übertragungsprotokolle für KFZ: Grundlage für Echtzeitfähigkeit

Eine weitere Innovationskomponente lag im Bereich der IT-Architektur und der Übertragungsprotokolle im Fahrzeug, um echtzeitkritische Signale (z. B. Videoströme) zeitsynchron und verlässlich zu übertragen und zu verarbeiten. Hierzu erforschte TÜV NORD zusammen mit b-plus neuartige Kommunikationsverfahren und Architekturansätze, um anforderungsspezifische Übertragungsverfahren und deterministische Synchronisationszeiten zu ermöglichen.

Im Vordergrund standen die Ermittlung der Funktions-, Vernetzungs- und Sicherheitsanforderungen unter Einbeziehung der hohen EMV-Anforderungen im KFZ-Bereich und die Auswahl und Erweiterung geeigneter Vernetzungstechnologien.

Datenerfassung und Labeling

Im Rahmen des Projekts hat CMORE den „Cost-Sensitive-Learning“ Ansatz zur Aufzeichnung und Annotation (Labeling) von Videodaten zu einem Expertensystem im Bereich hochautomatisiertes Fahren weiterentwickeln. Aktuell wurden die Videos nachträglich manuell annotiert. CMORE hat zur Optimierung der Kosten und zur Beschleunigung des Annotationsprozesses für diesen speziellen Anwendungsfall einen neuen Active-Learning Ansatz entwickeln. Der neue Ansatz konnte dann ebenso in anderen Spezialfällen für das hochautomatisierte Fahren angewendet werden. Das Innovationsthema „Innovative Labelingtools“ wurde bei CMORE durchgeführt.

1.2 Voraussetzungen

Am 26. Oktober 2015 veröffentlichte das Bundesministerium für Wirtschaft und Energie (BMWi) eine Bekanntmachung zur Förderung von Forschungsprojekten auf dem Gebiet „Hoch- und vollautomatisierten Fahren für anspruchsvolle Fahrsituationen“. Aufgrund dieser Bekanntmachung entstand das Projekt AutoConstruct.

Baustellen stellen für das Thema hochautomatisiertes Fahren eine erhebliche Herausforderung dar. Durch die Zunahme des Straßenverkehrs und die Nutzung von schweren LKWs werden die Fahrbahnen sehr stark beansprucht, so dass Fahrbahndecke und Tragschicht einem stärkeren Verschleiß unterliegen. Folglich müssen die Fahrbahnen ausgebessert, repariert und erweitert werden. Es ist zu erwarten, dass die Anzahl von Baustellen deswegen zukünftig weiter zunehmen wird.

Bereits aktuell stellen die Baustellenbereiche eine wesentliche Unfallquelle dar, da die Fahrbahnen in der Regel verengt sind, häufig Stausituation entstehen und die Führer der Fahrzeuge sich oftmals unsicher und gestresst verhalten. Für das hoch- und vollautomatisierte Fahren stellen Baustellen eine äußerst komplexe Situation dar. Die Fahrbahnen sind verengt und ihr Verlauf stark verändert. Häufig sind baustellenspezifische Fahrbahnmarkierungen den ursprünglichen Markierungen überlagert. Baken und Leitkegel begrenzen die Fahrbahnen und sind sicher zu erfassen. Darüber hinaus gibt es in Baustellenbereichen eine Vielzahl von komplexen Verkehrszeichen, die unterschiedliche Informationen (Geschwindigkeit, Fahrspurenverlauf, usw.) enthalten. Außerdem befinden sich in den Baustellenbereichen oftmals Baufahrzeuge, Fußgänger oder andere Objekte, die bei der Auswertung des Umgebungsfeldes zu berücksichtigen sind. Dies gilt besonders für Baustellen außerhalb von Autobahnscenarien (Land- und Innerortsstraßen). Daher besteht erhöhter Bedarf für hoch- und vollautomatisierte Fahrerassistenzsysteme, eine performante Lösung bereitzustellen, die den Fahrer bei der Baustellendurchfahrt stark entlastet.

Das nachfolgende Bild verdeutlichen beispielhaft die Komplexität von Baustellen:

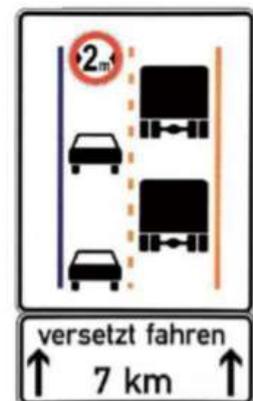


Abbildung 1: Baustellenbereich (Fotoquelle ADAC) und komplexe Verkehrsschilder

Ziel des Projektes war es daher, eine voll-integrierte Lösung für die Erkennung von Baustellenbereichen zu entwickeln, die ein hoch-automatisiertes Fahren und Steuern in diesen Bereichen ermöglicht. Die angestrebte Lösung sollte soweit prototypisch entwickelt werden, dass diese in realen Fahrzeugen verbaut und erprobt werden konnte. In einer Reihe von Testfahrten sollte sichergestellt werden, dass diese Lösung funktionsreif ist und einen „Technology Readiness Level“ von mindestens TRL 5 erreicht und die Laborsituation (TRL 4) verlässt. Die Lösung zur Baustellenerkennung sollte in einem KFZ-Versuchsaufbau integriert werden und in realer Einsatzumgebung erprobt und ausgewertet werden.

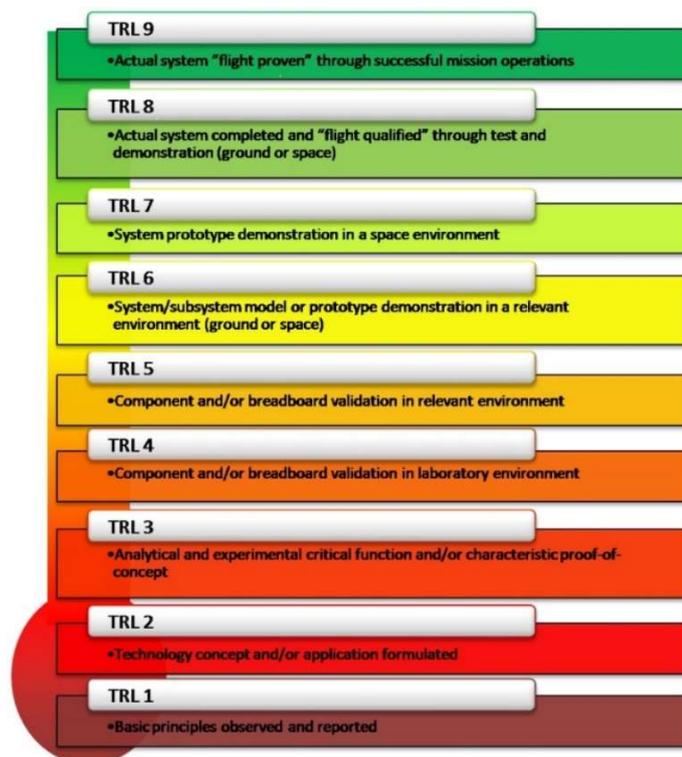


Abbildung 2: Technology Readiness Level

Zur Realisierung der Lösung wurden Innovationen im Bereich der echtzeitfähigen Sensorerkennung mit Schwerpunkt Bilderkennung und der Integration der Sensorkomponenten in eine sichere und echtzeitfähige KFZ-Kommunikations-Umgebung vorangetrieben. In der Bilderkennung wurden echtzeitfähige Verfahren zur Erkennung von komplexen Schildern, überlagerten Fahrbahnmarkierungen und die Erkennung von baustellentypischen Begrenzungen (z. B. Baken, Leitkegel, usw.) angestrebt. Grundlage dafür war das Aufzeichnen und die Annotation von vielfältigen Baustellenumgebungen. Dazu wurden innovative Annotationsverfahren von dem KMU-Partner CMORE entwickelt und erprobt. Eine weitere Innovationskomponente lag im Bereich der IT-Architektur und der Übertragungsprotokolle im Auto, um echtzeitkritische Signale (z. B. Videoströme) zeitsynchron zu übertragen und zu verarbeiten. Hierzu erforschte der TÜV NORD zusammen mit dem KMU b-plus neuartige Kommunikationsverfahren und Architekturansätze, wie beispielsweise IEEE802.1AS, um anforderungsspezifische und deterministische Synchronisationszeiten zu ermöglichen.

In dem Projekt fand eine Fokussierung auf das Baustellenszenario statt. Allerdings waren sämtliche innovativen Verfahren (komplexe Objekterkennung, neuartige Annotationssysteme, innovative IT-Architekturen, verbesserte Zeitsynchronisationsverfahren) relevant für weitere anspruchsvolle Fahrsituationen.

1.3 Planung und Ablauf des Vorhabens

Das Projekt war in sechs Arbeitspakete (AP0 – AP5) und vier Meilensteine (MS1 – MS4) gegliedert. Jedes AP wurde in mehrere Teilarbeitspakete (TP) strukturiert. Auf die in jedem TP von jedem beteiligten Verbundpartner erbrachte Arbeiten wurde im Dokument Vorhabenbeschreibung in den Abschnitten 3.1.0 – 3.1.5 detailliert eingegangen. Eine Übersicht über alle APs, TPs, und den Umfang der beteiligten Partner bietet die Ressourcentabelle in Abschnitt 1.3.2.

Die Konsortialführung im Projekt AutoConstruct obliegt Continental (AP0). Ferner war vereinbart, dass jeder Projektpartner mindestens ein Teilarbeitspaket leitete. In AP1 wurde durch den TÜV NORD, in Zusammenarbeit mit den übrigen Partnern die Mobilität sowie die Analyse der System- und Vernetzungsanforderungen vorgenommen und ein Architekturkonzept für die Umsetzung des Prototyps entwickelt. CMORE entwickelte mit Unterstützung der Partner in AP2 eine innovative Aufnahmeumgebung im Fahrzeug und die Labeling-Umgebung, die zur Annotation der Sensordaten verwendet wurde. In AP3 wurden die Verfahren zur Erkennung Baustellen-relevanter Informationen mittels serientauglicher Kamerasysteme ermittelt. Im AP4 wurden die verschiedenen Sensordaten über einen hoch performanten Ethernet-Kommunikationsbus miteinander im Auto vernetzt und sämtliche Komponenten zu einer Anwendung integriert. Schließlich erfolgte die Evaluierung des Gesamtsystems in AP5.

Arbeitsteilung im Verbund

Continental:

Im Projekt AutoConstruct mussten für ein sicheres und effizientes Erkennen von Baustellensituationen wissenschaftliche Fragestellungen bearbeitet werden. Diese wurden sowohl von den neutralen Forschungseinrichtungen als auch von dem Industriepartner (Continental) bearbeitet.

Hauptbeitrag von Continental war die Entwicklung und Lieferung von Funktionen und Software-Modulen zur Baustellenerkennung. Die Funktionen und SW-Module hatten einen hohen Einfluss auf die Erkennungsperformance des Gesamtfahrzeugs. Dabei wurden sowohl bereits vorhandene Verfahren weiterentwickelt (z. B. Erkennung von eckigen Verkehrszeichen, US), als auch neue Ansätze erprobt.

Der Automobilzulieferer war des Weiteren für die Gesamtkoordination des Projektes verantwortlich, mit Unterstützung der Verantwortlichen der Teilarbeitspakete.

Für eine kontinuierliche Weiterentwicklung waren diese eng mit den Fahrerprobungen und Labortests der KMUs CMORE und b-plus gekoppelt. Zu den spezifischen Aufgaben gehörten die Projekt- und Ressource-Planung, das Koordinieren und Nachverfolgen der einzelnen Arbeitspakete sowie die Moderation und Unterstützung von Lösungsfindungen.

TÜV NORD Mobilität:

Im Rahmen des Forschungsvorhabens übernahm TÜV NORD die Leitung und Bearbeitung des Arbeitspaketes 1 „Architektur“. Dabei wurden die anwendungsspezifischen System- und Vernetzungsanforderungen identifiziert sowie geeignete Technologien und Lösungsansätze analysiert und bewertet. Auf Basis der Analyseergebnisse wurde ein Konzept zur Vernetzungsarchitektur entwickelt und geeignete Übertragungsprotokolle zur effizienten und sicheren Übertragung der Objektdaten spezifiziert.

Im Arbeitspaket „Systemintegration Domaincontroller und Vernetzung“ evaluierte und bewertete TÜV NORD die Implementierung und Integration der Vernetzungsarchitektur in den Prototyp. Somit wurde die Serientauglichkeit des Lösungsansatzes verifiziert.

Im Arbeitspaket „Prototypenevaluierung und Validierung“ begutachtete TÜV NORD die Umsetzung des Prototyps und des Testkonzepts und stellt somit die Aussagekraft und Verwertbarkeit der Projektergebnisse sicher. Abschließend wurden aus den Ergebnissen der durchgeführten Prototypenerprobung relevante Anforderungen im Hinblick auf die Serienzulassung sowie Typgenehmigung und periodisch-technischer Überwachung abgeleitet.

CMORE:

Für das betreffende Forschungsvorhaben wurden der CMORE Automotive GmbH zwei Arbeitspakete zur Verantwortung übertragen. In beiden Paketen wurden nach Analyse der genauen Projektanforderungen aus AP1 innovative Lösungen zur Entwicklungsbegleitung und Validierung der komplexen Funktionen erarbeitet und validiert.

In AP2 wurde dabei mit neuen intelligenten Vernetzungs- und Messtechnikmethoden im Prototypenfahrzeug wertvolle Umgebungsinformation online bewertet und zum Teil schon während der Fahrt kategorisiert und strukturiert abgelegt. Hierzu wurde ein Verfahren entwickelt, welches einzelne Sensorinformationen in Echtzeit sinnvoll miteinander kombinierte und bewertet hat, um für die Entwicklung und Absicherung interessante Situationen online herauszufiltern. Nach der Anforderungsanalyse und der Implementierung der Messtechnik-Hardware und Software in Kombination mit den vernetzten Sensoren wurde das System im Prototypenfahrzeug erprobt.

Unter Berücksichtigung der gesamten Entwicklungstoolkette wurden die damit eingefahrenen Daten mittels einer speziell für den Anwendungsfall entwickelten automatischen Labeling-toolkette annotiert. Die generierten Referenzdaten und der zielgerichtete Aufbau von Spezialdatenbanken für Baustellenszenarien sind das Ergebnis dieses Arbeitspaketes.

In AP5 wurden die neu entwickelten Fusionsalgorithmen im Fahrzeug in den Zielsituationen erprobt.

Dafür wurden spezielle Testkataloge mit Hinblick auf die einzelnen Situationen ausgerichteten Tests entwickelt und so modular und flexibel aufgebaut, dass eine Standardisierung im nächsten Schritt ermöglicht wurde.

Aus den aufgenommenen Testdaten wurden die vorab definierten Key Performance Indikatoren (KPIs) teilautomatisiert berechnet. Hier wurden beispielsweise die Erkennungsrate, Fehldetektionen aber auch entstehende Latenzzeiten bewertet. Ebenso erfolgte eine Bewertung der Ergebnisse mit einem Ausblick und Empfehlungen für die nächsten Entwicklungs- und Validierungsschritte.

Das nachfolgende Schaubild beschreibt den von CMORE propagierten Entwicklungs- und Validierungsprozess für die Erstellung neuer Algorithmen und Funktionen. Wie in AP2 und AP5 definiert wurde durch die Einbeziehung funktionspezifischer Parameter eine Optimierung beim Einfahren der Daten erwartet. Weiterhin wurde eine Verbesserung beim Datenmanagement und der Erstellung von Referenzdaten angestrebt.

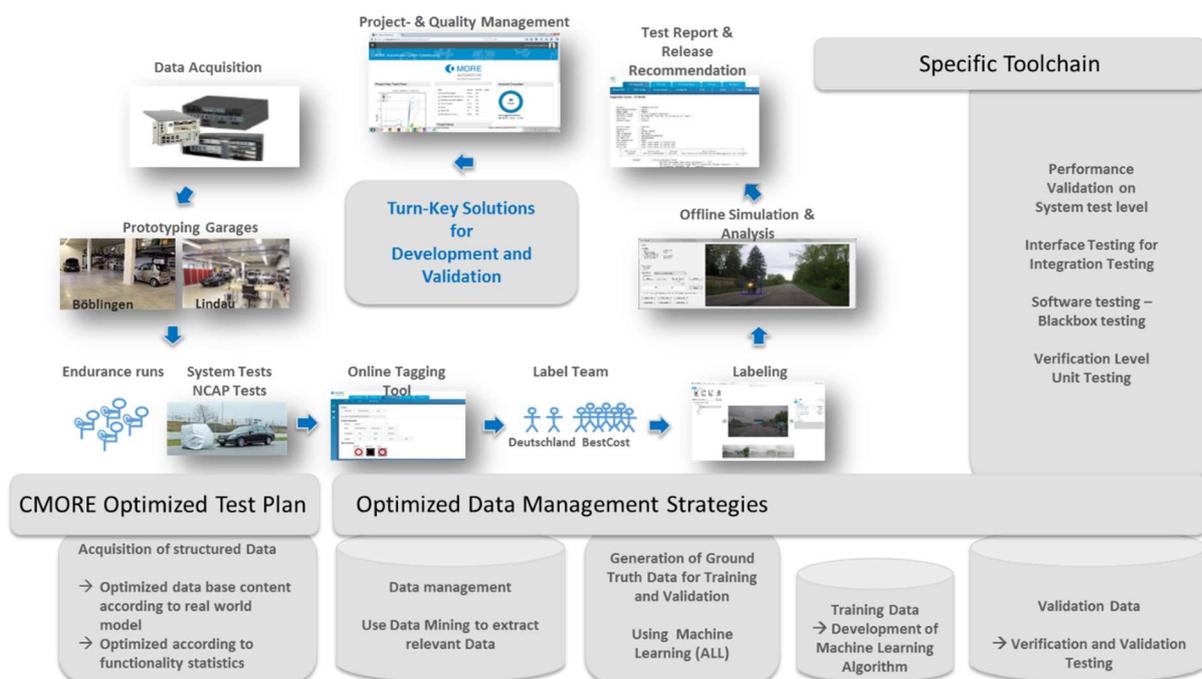


Abbildung 3: Entwicklungs- und Validierungsprozess für neue Funktionen und Algorithmen

Fraunhofer:

Im Rahmen des Projekts übernahm Fraunhofer IAIS die Leitung des AP 3 „Sensorik & Signalerkennung“ und koordinierte die technisch-wissenschaftlichen Entwicklungen zur Erkennung von Baustellen relevanten Informationen. Dazu arbeitete Fraunhofer IAIS in enger

Abstimmung mit dem Konsortialführer Continental. Ein wesentlicher Schwerpunkt der Entwicklungsarbeiten des Fraunhofer IAIS war die Erforschung und Umsetzung von Bilderkennungsverfahren, um Baustellenobjekte (Baken, Schilder, Hindernisse, usw.) exakt zu erkennen und die 3D Position zu bestimmen.

Darüber hinaus wurden Verfahren zur Erkennung und Differenzierung von zusätzlichen Fahrbahnmarkierungen in Baustellenbereichen entwickelt. Die eingesetzten Algorithmen und Verfahren basierten auf neuesten Ansätzen des Deep Learnings (z. B. Convolutional Neuronal Networks). Die Umsetzung der Verfahren zur Bilderkennung bzw. Sensoranalyse erfolgten in C/C++.

Dabei konnte auf die bereits vorhandene IAIS-interne Imagelib zurückgegriffen werden. Zusätzlich unterstützte das Fraunhofer IAIS die Projektarbeiten im Bereich der Anforderungsanalyse, Datenaufbereitung und bei der Integration in das Gesamtsystem.

Die Arbeitsteilung innerhalb des Verbundes war über die Abbildung 4 auf der Folgeseite zusammengefasst.

b-plus:

Im Projekt AutoConstruct übernahm b-plus die Leitung des Arbeitspaketes AP4 „Systemintegration Domaincontroller und Vernetzung“. In diesem Arbeitspaket erfolgte die Implementierung der Vernetzungsarchitektur, der Aufbau und Implementierung eines ECU Prototypen Frameworks, der Aufbau einer Messanordnung zur Datensammlung sowie die Erstellung eines Laboraufbaus. Dabei sollte eine Vernetzungsarchitektur mit extrem hoher Bandbreite erstellt werden, die die Sensoren mit einer hoch performanten Prototypen Plattform verband.

In AP1 unterstützte b-plus die Projektpartner bei der Analyse der Anforderungen sowie der Auswahl der geeigneten Vernetzungsarchitektur, die dann in AP4 von b-plus implementiert wurde. Dabei wurden von Seiten b-plus insbesondere die Themen Zeitsynchronisation, echtzeitfähige deterministische Übertragung sowie Hochverfügbarkeit betrachtet.

In AP2 unterstützte b-plus CMORE bei der Erstellung des Konzeptes für das Versuchsfahrzeug, sowie beim Fahrzeugaufbau, insbesondere bei der Integration der Messanordnung.

In AP5 sollte basierend auf dem in AP4 erstellten Laboraufbau sowie dem Versuchsfahrzeug die im Projekt verwendete Vernetzungsarchitektur und erstellte Prototypenplattform bewertet werden. Basierend auf diesen Ergebnissen sollten Empfehlungen für zukünftige Fahrzeugarchitekturen und Rechnerplattformen für autonom fahrende Fahrzeuge erarbeitet werden.

1.3.1 Übersicht Arbeitsteilung

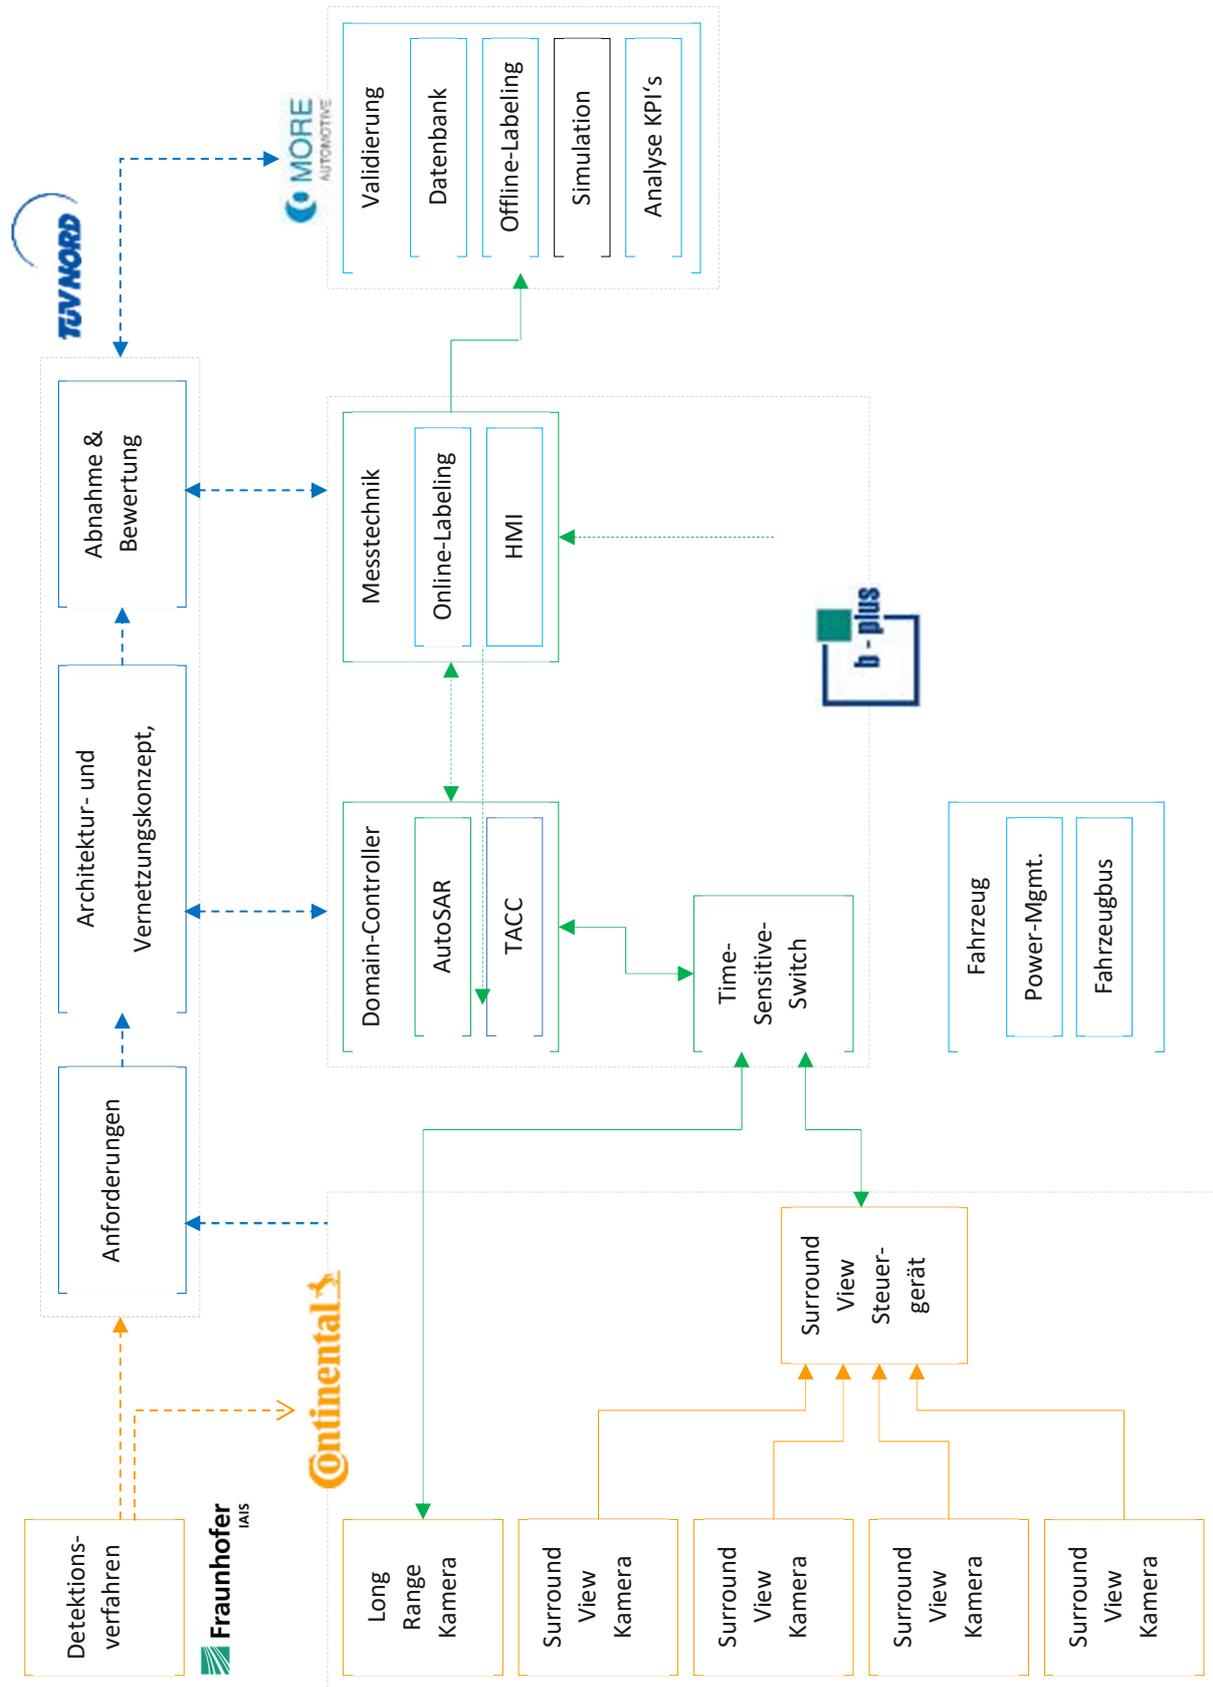


Abbildung 4: Übersicht Arbeitsteilung

1.3.2 Planung und Ablauf des Vorhabens

AP	Continental	CMORE	b-plus	TÜV NORD	IAIS	Gesamt
0	Projektleitung (25 PM)					
0.1	12	0,4	0	0,25	1	13,65
0.2	4	0,6	2,5	0,5	0	7,6
0.3	3	0	0,5	0,25	0	3,75
1	Architektur (30 PM)					
1.1	0,5	0,5	1	3	0,5	5,5
1.2	0	0,5	1	4	0,5	6
1.3	0	0,5	1	8	0	9,5
1.4	0,5	0,5	2	6	0	9
2	Datensammlung und Fahrzeugaufbau (45 PM)					
2.1	0,2	2	1	0	0	3,2
2.2	0,2	8	1	1	0	10,2
2.3	0,2	6	0	0	0	6,2
2.4	0,2	14	0	0	1	15,2
2.5	0,2	10	0	0	0	10,2
3	Sensorik & Signalerkennung (118 PM)					
3.1	15	0,4	0	0	0	15,4
3.2	15	0,4	0	0	0	15,4
3.3	0	0,4	0	0	32	32,4
3.4	0	0,4	0	0	12	12,4
3.5	10	0,4	0	0	12	22,4
3.6	20	0	0	0	0	20
4	Systemintegration Domaincontroller und Vernetzung (22 PM)					
4.1	0,25	0,5	4	2	0	6,75
4.2	0,25	0,5	6	2	0	8,75
4.3	0,25	1	2	0	1	4,25
4.4	0,25	0	2	0	0	2,25
5	Prototypenevaluierung und Validierung (44 PM)					
5.1	0,2	3	0,5	1	0	4,7
5.2	0,2	8	0	0	1	9,2
5.3	0,2	12	0,5	0	0	12,7
5.4	0,2	10	0,5	1	0	11,7
5.5	0,2	4	0,5	1	0	5,7
Σ	83	84	26	30	61	284

Tabelle 1: Ressourcenplanung

1.3.3 Arbeitspaketplanung

Meilensteine im Projekt

Um den Fortschritt des Projektes zu verifizieren, sind nachfolgende Meilensteine vorgesehen:

M1 – Monat 6: Fertigstellung der Anforderungsanalyse

- Anforderungen für das Kommunikationssystem und die Sensoren liegen konkret vor
- Fahrzeugaufbau zur Aufnahme der Daten fertig
- *Labeling*-Vorgehen festgelegt

M2 – Monat 18: Sensoranalyse funktionsfähig

- Initiale Verfahren zur Erkennung von Baustellen-relevanten Informationen liegen vor und sind auf Algorithmen-Ebene evaluiert
- Erste echtzeitfähige Implementierungen der Verfahren
- Annotierte Baustellenobjekte liegen vor

M3 – Monat 30: Integriertes System im Versuchsfahrzeug

- Komplettsystem ist im Versuchsfahrzeug integriert
- Testfahrten können gestartet werden
- Es liegen überarbeitete Sensordatenanalyseverfahren für Baustellen vor
- Sämtliche Trainingsdaten sind vollständig annotiert

M4 – Monat 36: Projektabschluss, Evaluierung abgeschlossen

- Das Gesamtsystem zur Baustellenerkennung ist evaluiert und getestet
- Empfehlungen/Richtwerte zur Weiterentwicklung zur Serienreife liegen vor

	GANTT-Chart																																								
	1. Jahr					2. Jahr					3. Jahr																														
	Q1	Q2	Q3	Q4		Q1	Q2	Q3	Q4		Q1	Q2		Q3	Q4																										
AP0 Projektleitung (Continental)	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	33	Continental			
T0.1 Projektkoordination	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	33		
T0.2 Reviews																																									
T0.3 0																																									
T0.4 0																																									
T0.5 0																																									
AP1 Architektur (TUV Nord)																																								0	
T1.1 Anforderungsanalyse																																							0		
T1.2 System Architektur																																									
T1.3 Vernetzung																																									
AP2 Datensammlung und Fahrzeugaufbau (CMORE)																																							40		
T2.1 Konzept Fahrzeug	1	1	1	1	1																																	5			
T2.2 Fahrzeugaufbau																																						5			
T2.3 Einfahren von Daten																																						9			
T2.4 Labeln - Entwicklung Methode und Tool																																						12			
T2.5 Labeln von Daten																																						9			
AP3 Sensorik & Signalerkennung (Fraunhofer + Continental)																																						60	Continental		
T3.1 Erkennung von Begrenzungsobjekten (Barke, Fahrspur, Leitplanke...) für Bausteile I																																									
T3.2 Erkennung von komplexen Hinweischildern I																																									
T3.3 Erkennung von Begrenzungsobjekten (Barke, Fahrspur, Leitplanke...) für Bausteile II																																						30	Continental		
T3.4 Erkennung von komplexen Hinweischildern II																																									
AP4 Systemintegration und Vernetzung (b-plus)																																									
T4.1 Konzept zur Vernetzung der Systemkomponenten																																									
T4.2 Integration Prototypen im Fahrzeug																																									
AP5 Prototypenevaluierung und Validierung (CMORE)																																									
T4.1 Konzept und Planung der Validierung																																						36			
T4.2 Definition der KPI's und Abstimmung Toolkette																																						9			
T4.1 Planung und Durchführung und Fahrzeugtests																																						9			
T4.2 Analyse Fahrzeugtests und KPI Erstellung																																						9			

Abbildung 5: Projektplanung

1.4 Wissenschaftlicher und technischer Stand

Continental:

Das Thema der Baustellenerkennung wurde bereits als Anwendungsbereich in dem Teilprojekt „Assistenzsysteme / aktive Sicherheit“ im Rahmen des BMWi Forschungsprojektes AKTIV (Adaptive und kooperative Technologien für den intelligenten Verkehr)¹ angegangen. Hier kamen monokulare Videokameras zum Einsatz, um ein sogenanntes Occupancy Grid aufzubauen. Dazu wurden korrespondierende Pixel zwischen zeitlich aufeinanderfolgenden Messungen verglichen, um ein Umgebungsmodell für Baustellen zu berechnen. Diese Ansätze zielen darauf ab, genaue Umgebungsmodelle für Baustellen zu berechnen und anhand dieser Informationen eine Steuerung des Fahrzeugs durch eine Baustelle zu ermöglichen.

In der Dissertation von Wimmer [1] wurde die Erkennung von Leitbaken und -kegeln in Baustellenbereichen ausführlich untersucht. Beide Arten von Baustellenobjekten werden mit dem in dieser Arbeit entwickelten Algorithmen online mit 99 % Detektionsrate erkannt. Die Positionen werden mit einer Genauigkeit (RMSE²) von 8,7 cm bei Leitbaken und 12,6 cm bei Leitkegeln korrekt bestimmt. Gegenstand dieser wissenschaftlichen Arbeit ist die Untersuchung und der Aufbau einer Umfelderkennung und -modellierung von Baustellen für Fahrerassistenzsysteme. Als Sensor kam ein nach vorne ausgerichteter Laserscanner zum Einsatz; eine Videokamera lieferte Daten zur Erkennung von Fahrbahnmarkierungen. Dieser Lösungsansatz hat jedoch den Nachteil, dass diese Sensorik kostenintensiv, aufwändig (z. B. mechanisch bewegliche Laserscanner) und nur bedingt als Massenprodukt serientauglich einsetzbar ist.

Daher wurde im Projekt AutoConstruct ein anderer Ansatz verfolgt. Mittels der Kombination von verschiedenen Kamerasystemen (Mono-, Stereo-, Fern-/Nahfeld-Kameras) wurde ein stärker bildbasierender Ansatz verfolgt, um ein serientaugliches Konzept zu ermöglichen.

Ein weiterer Forschungs- und Entwicklungsschwerpunkt lag in der Erkennung und Interpretation von komplexen Verkehrszeichen. Während die Erkennung von Verkehrszeichen für runde Schilder (Tempolimits) schon als Produkt von Firmen wie z.B. Mobileye [2], Bosch [3], Continental [4] verfügbar sind und sehr hohe Erkennungsraten möglich sind (>99 %), gibt es erst wenige Forschungsarbeiten zum Thema komplexe Verkehrszeichen, auf denen sich Namen, Ziffern, diverse Richtungspfeile usw. befinden. Durch den wissenschaftlichen Fortschritt im Bereich der Mustererkennung (In [Schmidtbauer-TSR] werden Deep Learning Verfahren zur Erkennung von Verkehrszeichen verwandt), war zu erwarten, dass diese Verfahren zu weiteren praktischen Verbesserungen führen.

¹ Das Projekt wurde vom BMWi gefördert und wurde 2010 abgeschlossen. Die Quelle www.aktiv-online.org ist mittlerweile leider abgeschaltet. Für weiterführende Informationen kann man den Abschlussbericht beim BMWi anfragen.

² Root Mean Square Deviation

Hinsichtlich praktischer Lösungen zur Baustellenerkennung ist auf die prototypische Lösung von Bosch zu verweisen [5]. Dabei handelt es sich um eine automatische Begrenzungserkennung, die in Baustellen die Möglichkeit bietet, die Querlenkung des Autos so zu optimieren, dass Fahrzeuge in Baustellen mittig gelenkt werden. Die im Projekt AutoConstruct anvisierte Lösung ging erheblich über die von Bosch vorgestellte Lösung hinaus, da sowohl Fahrbahnmarkierungen als auch komplexe Verkehrszeichen ausgewertet werden sollten.

Darüber hinaus ist im Kontext dieses Projektes das Google Patent [6] zu erwähnen. Google arbeitet mit Hochdruck an dem Thema autonomes Fahren und beabsichtigt durch die Anmeldung von Patenten diesen Bereich strategisch abzusichern. In der veröffentlichten Patentschrift steht eher die Anwendung als Ganzes im Mittelpunkt. Genaue Verfahren werden nicht ausführlich dargestellt, so dass aktuell Abgrenzungen schwierig zu treffen sind.

b-plus:

Über die komplette Laufzeit des Projektes wurde der aktuelle wissenschaftliche und technische Stand, der im Rahmen des Projektes betrachteten Themen, intensiv verfolgt und die potenziellen Auswirkungen auf die Arbeiten analysiert.

Zu Projektstart waren in Fahrzeugen größtenteils Architekturen mit im Fahrzeug verteilten intelligenten Sensoren im Einsatz. Dies bedeutet, dass lokal in den einzelnen Sensoren die Erkennung von Objekten erfolgte. Dabei kamen zur Vernetzung teilweise immer noch klassische Bussysteme zum Einsatz. Es war jedoch bereits erkennbar, dass sich die Fahrzeugarchitektur weg von klassischen Automotive Bus Systemen hin zu Automotive Ethernet Netzwerken entwickelt. Diese Veränderung bietet neben den höheren Datenraten eine wesentlich veränderte Architektur von durch Ethernet Switches verbundenen Punkt zu Punkt Verbindungen. Der Einsatz von Automotive Ethernet war zu diesem Zeitpunkt jedoch noch sehr begrenzt, er beschränkte sich dabei im Wesentlichen auf kleinere abgeschottete Funktionen im Fahrzeug. Vor allem kleinere 100 Mbit/s Ethernet Netzwerke waren im Fahrzeug zu finden. Auch bei Projekt Ende entsprachen 100 Mbit/s Ethernet Netzwerke immer noch dem Stand der Technik in Serienfahrzeugen, wobei die im Projekt betrachtete 1000 Mbit/s Automotive Ethernet Technologie (1000BASE-T1) bereits in zukünftige Serienfahrzeuge eingeplant ist. Die Standardisierung zu 1000BASE-T1 wurde ungefähr zu Projektstart von AutoConstruct fertiggestellt. Die Standardisierung von Ethernet PHYs für Automotive Anwendungen mit höheren Übertragungsraten wurde erst während der Laufzeit des Projektes AutoConstruct gestartet. Da bis Projektende keine Automotive 10 Gbit/s Ethernet PHYs zur Verfügung standen, wurden im Projekt 10GBASE-T PHYs verwendet.

Der Einsatz zentraler Vernetzungsarchitekturen mit hochbandbreitigen Anbindungen von Rohdatensensoren war zu Projektstart nicht verbreitet, es wurden im wesentlichen vorverarbeitete Objektdaten oder komprimierte Daten der Sensoren im Automobil verteilt.

TÜV NORD Mobilität:

Grundlage der Arbeiten von TÜV NORD Mobilität im Verbundprojekt war die Untersuchung von Anforderungen, konzeptioneller Methoden und die Ableitung von Lösungsvorschlägen zur Entwicklung von Systemarchitektur und Systemsicherheit beim hoch- und vollautomatisierten Fahren.

Auf dem Themengebiet der Vernetzungstechnologien für den Automobileinsatz wird die Technologie 100BASE-T1 in E/E Fahrzeugarchitekturen verschiedener Hersteller bereits eingesetzt. Aktuelle Entwicklungen zeigen zudem die Einführung des 1000BASE-T1 Standards. Spezifizierte Prüfverfahren für beide Technologien sind im Zuge der Serienentwicklung in die Anwendung übergegangen.

Automobilspezifische Technologiestandards mit höheren Datenraten von 2.5 Gbps, 5 Gbps und 10 Gbps sind aktuell Gegenstand von Standardisierungsarbeiten. Zudem wurde mit der Entwicklung von Spezifikationen für automobilspezifische Technologien für 25 Gbps und 50 Gbps begonnen. Die Entwicklung der automobilspezifischen Technologie-Standards und geeignete Prüfverfahren für Übertragungstechnologien im Multi-Gbps Bereich wird voraussichtlich die nächsten Jahre fort dauern.

Auf den höheren Schichten der Vernetzungsprotokolle haben Basistechnologien aus der TCP/IP [7] Familie Einzug in moderne Fahrzeugarchitekturen gehalten. Die Einführung automobilspezifischer Protokolle wie beispielsweise SOME/IP [8] zur service-orientierten Datenübertragung sind mittlerweile Teil des AUTOSAR [9] Standards und ermöglichen die Entwicklung neuer Kommunikationsparadigmen in Fahrzeugnetzwerken.

Zur Zeitsynchronisation wurden Technologien wie beispielsweise AVB (Audio/Video Bridging) und TSN (Time-Sensitive Networking) entwickelt. Entwicklungen zum automobilspezifischen Einsatz und geeignete Prüfverfahren befinden sich derzeit noch in der Umsetzung.

Im Bereich der sensorbasierten Objekterkennung für das automatisierte Fahren finden aktuell zahlreiche Forschungs- und Entwicklungsprojekte statt. Die Entwicklungen orientieren sich dabei unter anderem auf Funktions-Algorithmen für die Objekterkennung, performante Plattformen für eingebettete Systeme und Lösungen zur Funktionsvalidierung mittels kombinierter Ansätze aus simulations- und realfahrtbasierten Verfahren. Derzeit existieren noch keine standardisierten Vorgaben hinsichtlich Performanz- und Akzeptanz-Kriterien für automatisierte Fahrfunktionen und den eingesetzten Technologien. Ebenso fehlen serienreife Technologien, durchgängige Sicherheitsprozesse und Nachweisverfahren für automatisierte Fahrzeuge.

Zur Spezifikation von Anforderungen für den Einsatz von KI-basierten Technologien wird aktuell eine Normungs-Roadmap DIN erstellt, welche unter anderem allgemeine Anforderungen an Qualität und Nachweispflichten als auch mobilitäts-spezifische Aspekte berücksichtigen soll.

Mit der ISO 21448 wird aktuell ein Sicherheitsstandard entwickelt, der Methoden zur sicheren Entwicklung der beabsichtigten Funktion von Straßenfahrzeugen beim Einsatz von Sensor-Technologien und komplexen Algorithmen in Fahrerassistenzsystemen und automatisierten Fahrfunktionen beschreiben soll.

Die Einführung automatisierter Fahrzeuge in den öffentlichen Straßenverkehr ist derzeit nur über Ausnahmegenehmigungen für Erprobungsfahrzeuge möglich. Aktuell wird an Typgenehmigungsregelungen und Gesetzesvorlagen gearbeitet, die eine Einführung von automatisierten Fahrfunktionen in Serienfahrzeuge ermöglichen.

Fraunhofer:

Auf folgende Vorarbeiten, die eine Grundlage für die Projektergebnisse geleistet haben, wurde aufgebaut:

- Entwicklung von OCR-Verfahren [10]
- Entwicklung von Algorithmen zur Erkennung runder Verkehrszeichen mit Kreisdetektor, Erkennung und Verifikation mittels Deep Learning [11]
- Entwicklung von Algorithmen zur Erkennung dreieckiger Verkehrszeichen mit Dreieckdetektor, Erkennung und Verifikation mittels Deep Learning
- Entwicklung von Algorithmen zur Erkennung rechteckiger U.S. Geschwindigkeitsbegrenzungszeichen mit Rechteckdetektor, Erkennung und Verifikation mit Deep Learning [12]

1.5 Zusammenarbeit mit anderen Stellen

Ausgehend von der zu erbringenden Gesamtleistung hat sich folgende Kooperation als Verbundpartner ergeben:



CMORE Automotive GmbH

Kemptener Straße 99
88131 Lindau (Bodensee)



b-plus GmbH

Ulrichsberger Straße 17
94469 Deggendorf



TÜV –NORD Mobilität GmbH & Co. KG

IFM – Institut für Fahrzeugtechnik und Mobilität
Am TÜV 1
30519 Hannover



**Fraunhofer-Gesellschaft zur Förderung der angewandten
Forschung e.V.**

Fraunhofer-Institut für Intelligente Analyse- und
Informationssysteme IAIS,
Schloss Birlinghoven
54754 Sankt Augustin



Continental AG

ADC Automotive Distance Control Systems GmbH
Peter-Dornier-Straße 10
88131 Lindau (Bodensee)

Während der gesamten Projektlaufzeit haben die Projektpartner eng zusammengearbeitet. Zwischen den Parteien besteht ein Vertragsverhältnis welches die gemeinsame Durchführung des Verbundprojektes AutoConstruct zur echtzeitfähigen Umfelderkennung von Baustellen mittels serientauglicher und kostenoptimierter Kamera-Sensorik für das hoch- und vollautomatisierte Fahren, durch die Verantwortlichen beinhaltet.

TÜV NORD Mobilität:

Auf Grundlage der von TÜV NORD Mobilität entwickelten Arbeitsergebnisse wurden Erkenntnisse und Lösungsvorschläge abgeleitet und entsprechend der übergeordneten Ziele des Forschungsprogramms der Wirtschaft und Wissenschaft zugänglich gemacht. Weiterhin wurden Erkenntnisse in die industrielle Normung und die Vorschriftenentwicklung eingebracht. Diesbezüglich wurden während der Projektlaufzeit mehrere Vorträge auf Fachtagungen durchgeführt und Erkenntnisse in Form von Kommentierungen und Vorschlägen in Arbeitsgruppen zur Erarbeitung von neuen Vernetzungsstandards, Sicherheitsnormen und Fahrzeugtypgenehmigungsregelungen für die Automobilindustrie eingebracht. Zudem wurden Erkenntnisse von TÜV NORD Mobilität aus dem Projekt AutoConstruct in der VdTÜV-BSI Arbeitsgruppe Künstliche Intelligenz vorgestellt.

2. Eingehende Darstellung

In diesem Abschnitt werden die, im Projekt AutoConstruct bearbeiteten Arbeitspakete und deren Ergebnisse genauer dargestellt.

2.1 Verwendung der Zuwendung

Grobes Projektkonzept alle Projektpartner/Projektschwerpunkte:

Das Projekt war in sechs Arbeitspakete und vier Meilensteine organisiert. Die Arbeitspakete wurden in Tabelle 1 mit den Ressourcen der Projektpartner aufgeführt. Bei der Durchführung der Arbeitspakete war angedacht, dass die Konsortialleitung bei Continental liegt und jeder Projektpartner mindestens ein Teilarbeitspaket leitet. Im AP1 wurde durch TÜV NORD Mobilität in Zusammenarbeit mit den übrigen Partnern die Analyse der System- und Vernetzungsanforderungen vorgenommen und ein Architekturkonzept zur Umsetzung des Prototyps entwickelt. CMORE entwickelte mit Unterstützung der Partner im AP2 eine innovative Aufnahmeumgebung im Fahrzeug und Labeling-Umgebung, die zur Annotation der Sensordaten verwendet wurde. Im AP3 wurden die Verfahren zur Erkennung Baustellenrelevanter Informationen mittels serientauglicher Kamerasysteme entwickelt. Im AP4 waren

AP Nr.	Name des Arbeitspakets	Continental	CMORE	b-plus	TÜV NORD	Fraunhofer IAIS	PM Total
0	Projektleitung	17	1	1	1	1	21
1	Architektur	1	2	6	21	1	31
2	Datensammlung und Fahrzeugaufbau	1	40	2	1	1	45
3	Sensorik & Signalerkennung	60	2	0	0	56	118
4	Systemintegration Domaincontroller und Vernetzung	1	2	16	4	1	24
5	Prototypenevaluierung und Validierung	1	37	2	3	1	44
	Gesamt	81	84	27	30	61	283

Tabelle 2: Aufteilung des Projektaufwands

die verschiedenen Sensordaten über einen hoch performanten Ethernet-Kommunikationsbus miteinander im Auto vernetzt und sämtliche Komponenten zu einer Anwendung integriert. Die Evaluierung des Gesamtsystems erfolgte im AP5. Im Folgenden werden die Arbeitspakete ausführlich beschrieben und ihnen Personenmonate (PM) zugeordnet. Vorab erfolgt eine Übersicht zur Verteilung der Personenmonate über die einzelnen Partner und Arbeitspakete Tabelle 1.

Arbeitspakete im Projekt

Zur Erreichung der Meilensteine und des Gesamtziels waren folgende Arbeitspakete vorgesehen:

AP 0: Projektleitung

Aufwand:

Continental (17 PM), CMORE (1 PM), b-plus (1 PM), TÜV-NORD (1 PM), Fraunhofer IAIS (1 PM)

Arbeitspaket 0 befasste sich mit dem organisatorischen und technischen Projektmanagement und stellte daher den Rahmen zur kollaborativen Zusammenarbeit. Durch wöchentliche Telefonkonferenzen, persönliche Projekttreffen, zusätzlichen bi- und trilaterale Treffen/Telefonkonferenzen sowie durch stetigen E-Mail-Verkehr konnte ein enger Kontakt mit den Projektpartnern sichergestellt werden.

Jedes Teilprojekt war durch die Anforderungen und Rahmenbedingungen aus der Industrie (Hersteller, Zulieferer und Prüfeinrichtungen) und dem Ziel der Gestaltung innovativer, zukünftiger Produkte geprägt, um die Praxisrelevanz der erzielten Forschungs- bzw. Entwicklungsergebnisse zu gewährleisten. Das Projektmanagement unterstützte und lenkte dabei die Ausgestaltung des Gesamtprojektes. Dazu gehörten die Abstimmung der Partner untereinander und die Kommunikation mit dem Projektträger inklusive Berichtswesen.

Das Ergebnis sollte ein abgesichertes Vorgehen inklusive des zur Umsetzung notwendigen Instrumentariums zur Freigabe von hochautomatisierten Erkennungsfunktionen sowie deren praktische Erprobung sein.

Folgende Teilarbeitspakete wurden bearbeitet:

- TP 0.1: Projektkoordination
- TP 0.2: Reviews

AP 1: Architektur

Aufwand:

Continental (1 PM), CMORE (2 PM), b-plus (6 PM), TÜV-NORD (21 PM), Fraunhofer IAIS (1 PM)

Zukünftige Fahrerassistenzsysteme zur Verkehrszeichen- und Fußgängererkennung in Baustellenbereichen berechnen Entscheidungen basierend auf Daten, die von verschiedenen Fahrzeugsensoren erfasst und an die zentrale Recheneinheit übermittelt werden. Die Funktion ist dabei in einem verteilten System implementiert, bei dem einzelne Netzwerkteilnehmer sicherheitsrelevante Daten in Echtzeit übertragen. Dabei übersteigen die technischen Anforderungen hinsichtlich der zu übertragenden Datenmengen und Übertragungsraten im Fahrzeug die technischen Eigenschaften heutiger Vernetzungstechnologien wie CAN oder *FlexRay* um ein Vielfaches. Auch neuste Vernetzungstechnologien der Automobilbranche, wie z. B. *BroadR-Reach* mit einer deutlich leistungsfähigeren Übertragungsrate von 100 MBit/s, genügen den technischen Anforderungen dieser zukünftigen Systeme nicht.

Neben einer geeigneten und kostengünstigen Technologie zur physikalischen Datenübertragung ist die Vernetzungsarchitektur auch hinsichtlich der deterministischen und sicheren Übermittlung der Sensordaten auszulegen. Hierzu werden software-basierte Übertragungsprotokolle benötigt, die auf die spezifischen Anforderungen der Assistenzfunktion und der Sensordaten ausgelegt sind.

Im Rahmen des Projekts wurden im Arbeitspaket Architektur die anwendungsspezifischen Systemanforderungen identifiziert und Vernetzungs- und Sicherheitsanforderungen abgeleitet. Dabei wurden sowohl Physical Layer Technologien mit ausreichender Übertragungsgeschwindigkeit als auch höhere Protokollschichten zur effizienten, deterministischen und fehlertoleranten Übertragung der Sensordaten berücksichtigt. Auf Basis der ermittelten Anforderungen wurden bestehende Technologien aus automobilfernen Branchen für den Fahrzeugeinsatz, sowie aktuelle Entwicklungen der Automobilindustrie in Forschung und Standardisierung, analysiert und bewertet. Bei der Analyse wurden Diskrepanzen und Inkompatibilitäten mit den Automobilanforderungen identifiziert.

Zur Erprobung im Prototyp wurden geeignete Übertragungstechnologien ausgewählt und eine softwareseitige Protokoll-Spezifikation hinsichtlich der anwendungsspezifischen Vernetzungseigenschaften erstellt. Auf Basis der eingesetzten Technologien wurde eine anwendungs-spezifische Vernetzungsarchitektur konzipiert, die im Prototyp umgesetzt und erprobt wurde.

Ein Schwerpunkt der Arbeit lag dabei in der effizienten und kostengünstigen Auslegung des Systems auf das vernetzte Mikrocontrollersystem im Automobil. Ein wichtiger Erfolgsfaktor war dabei, die neuen Technologien im Automobil einzusetzen und dabei durch geeignete, anwendungsspezifische Protokolle zu erweitern. Hierfür musste die technische Umsetzung in

die Gesamtarchitektur des Fahrzeugnetzwerks integrierbar werden. Zudem musste die entwickelte Lösung die spezifischen Anforderungen an Funktionalität, Sicherheit, Robustheit und Kosten erfüllen. Die erarbeitete EE-Architecture kann der Abbildung 6 entnommen werden. Es waren zur Realisierung des AP folgende Teilarbeitspakete vorgesehen:

- TP1.1: Anforderungsanalyse
- TP1.2: Ableitung Gesamt-System Architektur
- TP1.3: Analyse Technologie und Lösungsansätze zur Vernetzung
- TP1.4: Konzept zur Vernetzung der Systemkomponenten (Netzwerk-HW/SW/Protokollschichten)

b-plus:

Das Arbeitspaket 1 beschäftigte sich mit der Identifikation und Auswahl von Technologien sowie die Erstellung einer Gesamtarchitektur. Zusammen mit den anderen Projektpartnern wurden Anforderungen an die Gesamtarchitektur analysiert. b-plus widmete sich dabei insbesondere in Zusammenarbeit mit den Partnern Continental, CMORE und TÜV Nord den Themenbereichen Vernetzung, Sensoranbindung, Zeitsynchronisierung, Quality of Service sowie Anbindung der Domaincontroller und Datenlogger. Der mit der Anforderungsanalyse verbundene Meilenstein M1 wurde erfolgreich erreicht.

Im Bereich der Kommunikationstechnologie zeichnen sich Trends hinsichtlich zu höheren Datenraten, einer rein Ethernet basierten Kommunikation sowie einer SerDes Kommunikation für asymmetrische Punkt-zu-Punkt Verbindungen für Kameras ab. Die SerDes Kommunikation basiert aktuell auf proprietären Kommunikationstechnologien einzelner Halbleiterhersteller. Im Projekt wurden in der zweiten Projektphase GMSL2 (eine SerDes Technologie) Kameras verwendet. Da es im Projekt, sowie eventuell auch zukünftig in autonomen Fahrzeugen, notwendig war, die Datenströme der Kameras an verschiedene Endsysteme zu senden (Multicast) war der Einsatz einer reinen Punkt-zu-Punkt orientierten Übertragungstechnologie wie GMSL2 nicht zielführend. Ethernet bietet mit Ethernet Bridges (Switches) ein bewährtes und leistungsfähiges Konzept zum Aufbau eines Netzwerkes zur zielgerichteten Verteilung der Daten. Auf Grund dessen, wurde ein rein Ethernet basiertes Kommunikationskonzept für die Vernetzung der einzelnen Komponenten umgesetzt. Das proprietäre GMSL2 wurde dementsprechend in GMSL2-Ethernet Gateways auf Ethernet gewandelt. Der Einsatz von Automotive Ethernet Varianten mit hohen Datenraten (>1 Gbit/s) konnte nicht betrachtet werden, da sich diese Varianten erst in der Spezifikations- bzw. Entwicklungs-Phase befanden. Es wurde daher auf 10GBASE-T zurückgegriffen.

Im Rahmen der Architektur wurden wesentliche, im AutoConstruct zum Einsatz kommende bzw. dafür relevante, Kommunikationsstandards und Technologien identifiziert.

- 100BASE-T1 Ethernet
- 1000BASE-T1 Ethernet
- 10GBASE-T Ethernet
- 40/50 Gigabit Ethernet

- Gigabit Multimedia Serial Link 2 (GMSL2)
- IEEE Std 802.1AS
- IEEE P802.1AS-Rev

Ein besonderes Augenmerk richtete sich auf die zuverlässige Zurverfügungstellung aller notwendigen Daten wie Kamerabilder, Fahrdynamikdaten, Kalibrierdaten und Metainformationen an den Datenlogger und das Prototypen System. Die Daten werden mit minimaler Zeitdifferenz an beiden Geräten empfangen.

Abweichend zur ursprünglichen Planung wurde die Architektur in zwei Ausbaustufen gegliedert. Dies ermöglichte es während der Projektlaufzeit auf neuere Technologien zu wechseln, die zu Beginn noch nicht verfügbar waren, gleichzeitig ermöglichte es das frühzeitige Einfahren von Daten für die Entwicklung der datengetriebenen Algorithmen. Die erste Ausbaustufe basierte auf fünf 100BASE-T1 Kameras (Automotive Ethernet), welche komprimierte Bilddaten als IEEE 1722 Stream versenden. Die Kameras sind an eine an „PoDL“ (Power over Dataline) angelehnten Adapter angeschlossen, dieser Adapter ist ein Prototyp und versorgt die Datenleitung mit der notwendigen elektrischen Energie, um eine Kamera zu betreiben. Eine zusätzliche Spannungsversorgung der Kameras ist nicht notwendig. Der Datenstrom aus der Kamera wurde mit Hilfe eines Ethernet-Switches (HiS_Switch) an alle Komponenten verteilt. Spezielle Anpassungen mussten am Switch durchgeführt werden, um die zeitliche Synchronisation der Automotive Kameras sicherzustellen und die Verteilung der Daten auf die definierten Komponenten zu ermöglichen. Abbildung 6 zeigt das Vernetzungskonzept der Ausbaustufe 1. Neben den Kameradaten wurde auch das bestehende Bussystem des Autos an die Messtechnik sowie das Prototypen System angeschlossen.

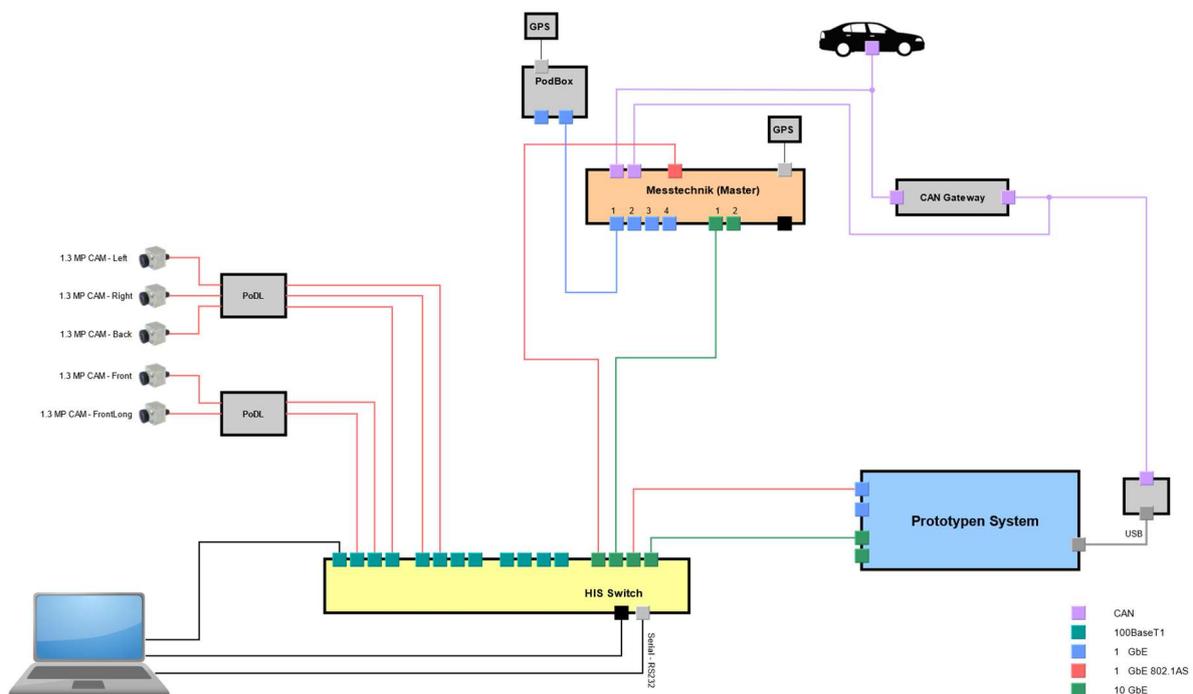


Abbildung 6: Vernetzungskonzept der Ausbaustufe 1

In Ausbaustufe 2 wurden die meisten Automotive Ethernet Kameras der ersten Ausbaustufe durch technologisch neuere 2.5 MP Raw Kameras ersetzt. Dies hat zur Folge, dass sich die zu verarbeitende Datenrate von ca. 150 Mbit/s um den Faktor 29 auf circa 4,3 Gbit/s signifikant vergrößert hat. Um diese Datenmengen bewältigen zu können, wurden performantere Technologien, wie 10GBASE-T, eingesetzt. Zusätzlich zum Technologiewechsel wurden weitere Komponenten in den Versuchsträger integriert. Das Prototypen System wurde mit einer 40Gbit/s Ethernet Netzwerkkarte ausgestattet. Zwei Messtechnik Adapter und ein weiterer Messtechnik Rechner sind im Versuchsträger verbaut worden. Als Datenverteiler wurde der HiS_Switch, welcher in Ausbaustufe 1 verwendet wurde, durch seinen Nachfolger den DecADE Switch ersetzt. Dieser ist mit zwölf 10GbE, zwei 40GbE und zwei 50GbE Schnittstellen ausgestattet und ist damit den neuen Anforderungen gewachsen.

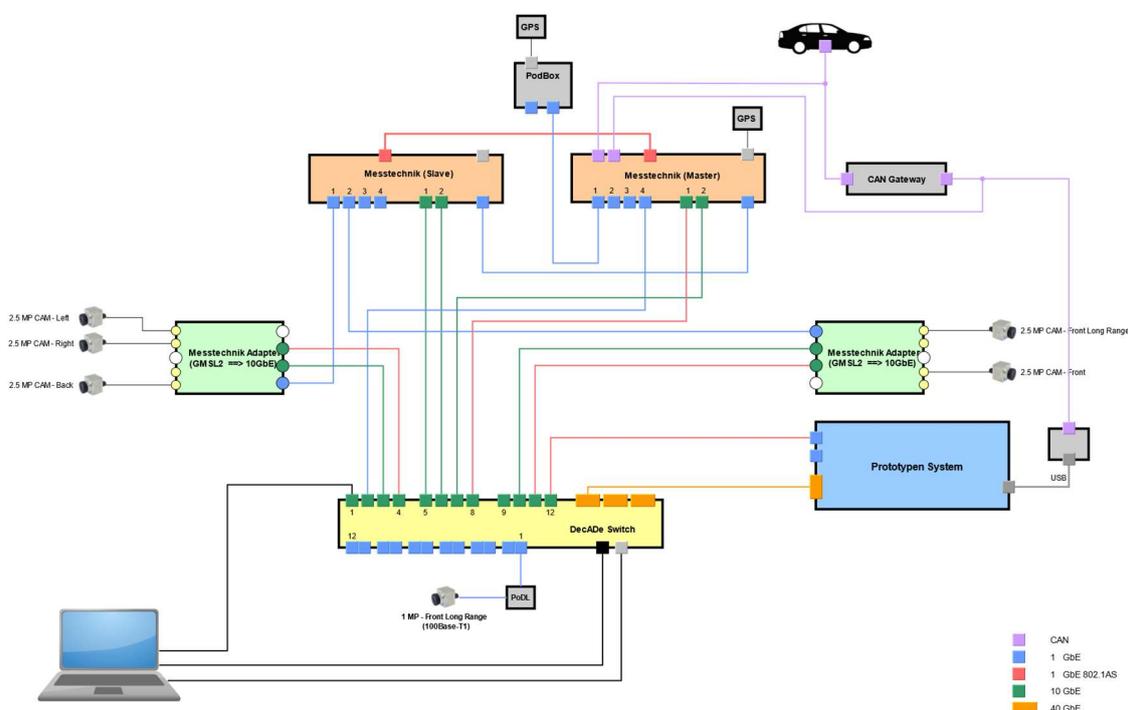


Abbildung 7: Vernetzungskonzept der Ausbaustufe 2

TÜV NORD Mobilität:

Identifikation funktionaler und nichtfunktionaler System-Anforderungen

Grundlage einer systemtechnischen Entwicklung ist die Analyse von Anforderungen und die Definition einer geeigneten Systemarchitektur. In den von TÜV NORD Mobilität durchgeführten Arbeiten wurden die funktionalen und nichtfunktionalen Anforderungen an eine Kamera-basierte Verkehrszeichendetektion zum automatisierten Fahren in Baustellensituationen identifiziert und eine Anforderungsspezifikation für den Versuchsträger erstellt.

Die Anforderungsanalyse wurde auf Applikations- und Systemebene und unter Berücksichtigung der beiden Ausbaustufen des Versuchsträgers durchgeführt.

Zur Ableitung der funktionalen Anforderungen wurde eine Analyse der zu detektierenden Verkehrszeichen in Baustellensituationen und Symbole nach StVO (einschließlich RSA) durchgeführt und Anforderungen an die zu erkennenden Objekte abgeleitet.

Zur Ableitung der nichtfunktionalen Anforderungen wurden Technologien in der Informationsverarbeitungskette, beginnend mit der Kamera-basierten Umgebungserfassung über die Digitalisierung und Vorverarbeitung von Sensordaten bis zur Objekt-Klassifikation mittels KI-gestützter Algorithmen analysiert. Dabei wurden Methoden zur Analyse der Anforderungen an die Verlässlichkeit der Systemfunktion konzipiert und am AutoConstruct Anwendungsfall erprobt.

Basis für die angewendeten Methoden zur System- und Sicherheitsanalyse bildeten der etablierte Sicherheitsstandard ISO 26262:2011 zur Funktionalen Sicherheit für Straßenfahrzeuge sowie zum Zeitpunkt der Projektbearbeitung verfügbare Konzepte und Entwürfe für neue Sicherheitsstandards wie z.B. ISO 26262:2018, ISO 21448 zur Sicherheit der beabsichtigten Funktion für Straßenfahrzeuge und ISO/SAE 21434 zur Entwicklung von Cybersicherheit für Straßenfahrzeuge. Im Projektzeitraum wurden folgende Untersuchungen zur Analyse der Sicherheitsanforderungen durchgeführt:

- Analyse der oben genannten Sicherheitsstandards und Ableitung eines ganzheitlichen Ansatzes zur Risikoanalyse und zur Ableitung von Sicherheits- und Validierungsanforderungen für die Verkehrszeichenerkennung zum automatisierten Fahren.
- Identifikation von Sicherheitsrisiken und der funktionalen Auswirkung in den verschiedenen Automatisierungsstufen mittels Gefahren- und Risiko-Analyse am Anwendungsfall AutoConstruct.
- Identifikation möglicher Ursachen im Signalverarbeitungsprozess und der funktionalen Auswirkungen in verschiedenen Automatisierungsstufen, inkl. Umwelterfassung (Sensorik), (Bild-)Datenverarbeitung, Objekt-Klassifikation sowie der elektronischen Datenübermittlung mittels eines kombinierten Ansatzes aus induktiven und deduktiven Analyseverfahren.
- Identifikation möglicher Stör- und Umgebungseinflüsse für die Kamera-Sensorik mittels System Weakness Analyse und Abgrenzung zwischen Prototyp- und Serien-Anforderungen.
- Ableitung und Klassifizierung von Sicherheitszielen beim Einsatz der Objekterkennung in verschiedenen Automatisierungsstufen gemäß SAE J3061.
- Erstellung allgemeiner Qualitäts- und Sicherheitsanforderungen und Klassifizierung hinsichtlich RAMMST-Kriterien zur Zuverlässigkeit, Verfügbarkeit, Instandhaltbarkeit, Betriebssicherheit, Informationssicherheit, Testbarkeit (vgl. DIN EN 50126)
- Abgrenzung der identifizierten Anforderungen zwischen dem AutoConstruct Versuchsträger und Serienfahrzeugen.

Auf Basis der Funktions- und Sicherheits-Anforderungen an die Verkehrszeichendetektion wurden allgemeine Prüfanforderungen abgeleitet, die bei der Validierung des AutoConstruct

Versuchsträgers sowie bei Fahrzeug- und Simulations-basierten Tests von Serienfahrzeugen Berücksichtigung finden können.

In Bezug auf die Verlässlichkeit von KI-Technologien zum Einsatz in Systemen für eine Bild-basierte Objekterkennung im Straßenverkehr wurde eine Untersuchung von Anforderungen und Einflussfaktoren hinsichtlich der Verlässlichkeit von Trainings- und Verifikations-Daten durchgeführt. Zur Analyse wurde eine prototypische KI-Umgebung auf Basis von TensorFlow aufgesetzt und am Anwendungsfall AutoConstruct durchgeführt.

Analyse von Vernetzungsanforderungen

Zur sicheren und zuverlässigen Umfelderkennung automatisierter Fahrzeuge sind hohe Datenmengen verschiedener Sensoren zu verarbeiten. Daraus lassen sich konkrete Anforderungen an die zu verwendende Hardware ableiten, wie zum Beispiel die Auflösung der Kamerasensoren sowie die Leistungsfähigkeit der Recheneinheiten, auf denen die Algorithmen zur Informationsverarbeitung ausgeführt werden. Daten verschiedener Kamerasensoren müssen fusioniert und in einer zentralen Recheneinheit verarbeitet werden. Hierzu muss eine geeignete Vernetzungsarchitektur realisiert werden, welche die technischen Anforderungen erfüllt. Im Rahmen der Projektbearbeitung wurden die Vernetzungsanforderungen zur Kamera-basierten Umgebungserfassung analysiert und eine Vernetzungsarchitektur in zwei Ausbaustufen für den AutoConstruct Versuchsträger konzipiert. Zusammenfassend lassen sich die Vernetzungsanforderungen nachfolgend gelisteten Kategorien zuordnen:

- **Übertragungsbandbreite**

Die Kamerasensoren erzeugen abhängig von der Bildauflösung, den Bildwiderholungsraten und der Bildkompression große Datenmenge. Diese Daten müssen mittels eines geeigneten Kommunikationssystems in Echtzeit von den Sensoreinheiten zu den verarbeitenden Systemkomponenten übertragen werden. Die Vernetzungsarchitektur und die verwendeten Kommunikationstechnologien müssen daher hinreichende Kapazitäten hinsichtlich der Datenrate zur Verfügung stellen.

- **Skalierbarkeit und Erweiterbarkeit**

Die Anzahl an Sensoren sowie die Datenmengen steigen mit der Weiterentwicklung der Fahrzeugfunktionen. So war es auch in der zweiten Ausbaustufe des AutoConstruct Versuchsträgers erforderlich, die Anzahl und Auflösung der Kamerasensoren zu erhöhen. Eine Auslegung der Vernetzungsarchitektur und die verwendeten Technologien sollten daher skalierbar und erweiterbar sein, um Weiterentwicklungen zeit- und kosteneffizient realisieren zu können.

- **Datenintegrität und Verfügbarkeit**

Um eine verlässliche Kommunikation sicherzustellen, musste die Vernetzungsarchitektur ein hohes Maß an Datenintegrität gewährleisten. Die Verfügbarkeit und Korrektheit der Daten mussten dabei durch Implementation geeigneter Mechanismen umgesetzt werden.

- **Zeitanforderungen verschiedener Anwendungen**

Für das automatisierte Fahren müssen Umgebungsdaten in Echtzeit verarbeitet werden, damit die Fahrfunktion innerhalb der notwendigen Zeitspanne auf die verschiedenen Umgebungssituationen reagieren kann. Hierdurch ergeben sich Anforderungen an die Kommunikationsarchitektur hinsichtlich der bei der Übertragung auftretenden Latenzzeiten. Weiterhin müssen Daten verschiedener Sensoren aggregiert und ausgewertet werden. Die Kommunikationsarchitektur muss daher eine geringe Latenz aufweisen und geeignete Mechanismen aufweisen, um Daten verschiedener Sensoren zu synchronisieren.

- **Kosteneffizienz und Wartbarkeit**

Aufgrund der Komplexität und hohen Anzahl der Systeme, müssen die eingesetzten Komponenten kosteneffizient zur Verfügung stehen. Außerdem muss eine einfache und kostengünstige Wartbarkeit der einzelnen, eingesetzten Komponenten über die Produktlebenszeit des Gesamtsystems gewährleistet werden können. Ein Zurückgreifen auf bereits standardisierte Komponenten ist dabei von Vorteil.

Ableitung der Gesamtsystemarchitektur

Auf Basis der ermittelten Anforderungen an die Vernetzungsarchitektur und Datenübertragung wurden aktuelle Entwicklungen der Automobilindustrie in Forschung und Standardisierung und auch bestehende Technologien aus automobilfernen Branchen für den Fahrzeugeinsatz analysiert und bewertet. Bestehende Inkompatibilitäten der Technologien mit Automobil-spezifischen Anforderungen wurden identifiziert und bei der Auswahl geeigneter Technologien berücksichtigt. Zudem wurden anwendungsspezifische Anforderungen des AutoConstruct Versuchsträgers für die echtzeit-basierte Umfelderkennung mittels kamerabasierter Sensorik abgeleitet.

Unter Berücksichtigung der identifizierten Vernetzungsanforderungen wurde in Zusammenarbeit der Projektpartner eine prototypische Vernetzungsarchitektur zur Erprobung entwickelt und in ein Versuchsfahrzeug integriert. Dabei sind die Ergebnisse der vorangegangenen Technologieanalyse in die Auswahl und Dimensionierung der einzelnen E/E Komponenten eingeflossen.

Als Basis der Kommunikationstechnik wurde hierbei eine Ethernet/IP-basierte Technologie ausgewählt, welche bislang insbesondere im Bereich der IT eingesetzt wird. Auch zum Einsatz in Fahrzeugnetzwerken bieten Ethernet-basierte Technologien entscheidende Vorteile gegenüber den herkömmlich eingesetzten Bussystemen wie FlexRay, CAN oder MOST. Neben höheren Datenraten bieten die Kommunikationsprotokolle auch bewährte Absicherungs-Funktionen und Mechanismen zur Skalierbarkeit. Um die automobilspezifischen Vernetzungsanforderungen zu genügen, ist die Weiterentwicklung der bestehenden Technologien zu einem Automotive Ethernet Kommunikationsstandard jedoch notwendig.

Während der Projektlaufzeit waren bereits erste Automotive Ethernet Komponenten für 100BASE-T1 und 1000BASE-T1 verfügbar, mit denen über zweiadrige un-geschirmte Kommunikationskanäle Datenraten von 100 Mbps und 1Gbps erreicht werden können. Im

Rahmen der Projektbearbeitung wurden diese Technologien und verfügbare Implementierungen hinsichtlich des Einsatzes in der Architektur evaluiert.

In der ersten Ausbaustufe des AutoConstruct Versuchsträgers wurde zur Vernetzung der Kameras mit dem Netzwerk-Switch die Technologie 100BASE-T1 eingesetzt. Die Anforderungsanalyse für die zweite Ausbaustufe ergab, dass die erforderlichen Datenraten über 1 Gbps hinausgehen. Zum Zeitpunkt der Projektbearbeitung standen Automotive spezifische Ethernet-Standards und entsprechende Implementierungen für Datenraten Multi-Gbps-Bereich noch nicht zur Verfügung. Daher wurde zur Vernetzung der Sensoren in der zweiten Ausbaustufe des Versuchsträgers und zur Anbindung der Recheneinheiten zur Datenaufzeichnungen und Datenverarbeitung verfügbare Multi-Gbps-Ethernet Technologien aus dem IT-Bereich eingesetzt. Es sei an dieser Stelle darauf hingewiesen, dass diese Technologien für den Einsatz in den Versuchsträger zweckdienlich waren, jedoch für einen Einsatz in Serienfahrzeuge eher ungeeignet sind. Die im Folgenden beschriebenen Analysen hinsichtlich der Anforderungen an die Kommunikationsarchitektur sowie die Entwicklung von Absicherungs- und Validierungskonzepten für die Datenkommunikation wurden daher schwerpunktmäßig auf Basis der zur Verfügung stehenden Automotive Ethernet Komponenten durchgeführt, da diese für die Verwendung in serientypischen Anwendungen ausgelegt wurden.

Analyse serientauglicher Vernetzungstechnologien und Nachweisverfahren zur Validierung

Im Rahmen der Projektbearbeitung wurden Technologieanforderungen und Konzepte zur Validierung der betrachteten Systemkomponenten entwickelt, prototypisch umgesetzt und erprobt. Neben der Identifikation von Vernetzungsanforderungen für automatisierte Fahrzeuge war das Ziel die Entwicklung serientauglicher Methoden, die zum Nachweis der Vernetzungsanforderungen hinsichtlich Funktionalität, Sicherheit und Robustheit eingesetzt werden können.

Auf Basis der in vorherigen Arbeitsschritten erfolgten Konzeption der Vernetzungsarchitektur und der Übertragungsprotokolle zur effizienten und sicheren Objektdaten-Übertragung wurde eine Sicherheitsanalyse zur Kommunikationsabsicherung durchgeführt. Hierzu wurde eine Methodik zur Untersuchung Architektur-Anforderungen an Datenintegrität und Datenverfügbarkeit definiert und eine Untersuchung der Sicherheitsanforderungen an die Kommunikationsabsicherung im Fahrzeugnetzwerk durchgeführt.

Bei einem risikobasierten Ansatz zur Entwicklung der Systemsicherheit wird jedem Sicherheitsziel auf Basis einer durchgeführten Gefahren- und Risiko-Analyse ein Integritätsniveau zugeordnet, mit dem das Risiko des Eintretens einer möglichen Fehlfunktion klassifiziert wird. Die definierten Sicherheitsziele und ihr jeweiliges Integritätsniveau übertragen sich dann auf die entsprechenden System-Anforderungen und Systemkomponenten. Auf dieser Basis können dann Grenzwerte für die akzeptierbaren Fehlerraten der Systemfunktionen ermittelt und geeignete Absicherungsmaßnahmen und Validierungsstrategien zum Nachweis der Effektivität der Sicherheitsfunktion konzipiert werden.

Untersuchung der Sicherheits-Anforderungen an die Kommunikationsabsicherung im Fahrzeugnetzwerk

Bei Betrachtung der Funktionalen Sicherheit bestimmt sich die Fehlerrate der Sicherheitsfunktion maßgeblich aus den zufälligen Hardware-Fehlern aller an der Funktion beteiligten Hardware-Komponenten. Beruhen die Sicherheitsfunktionen auf dem Austausch von Nachrichten über ein Kommunikationssystem, ist zudem die Störanfälligkeit der Übertragungstrecke durch Umgebungseinflüsse zu berücksichtigen.

Das Bitfehlerverhältnis (engl. Bit Error Rate) der Übertragungstrecke stellt hierbei einen relevanten Parameter für die Analyse hinsichtlich EMI-bedingter Störungen dar, die zu Hardware-Fehlern und zufälligen Übertragungsfehlern führen können. Um das erforderliche Maß an die Kommunikationsabsicherung zu bestimmen, wird ein Verfahren zur Bestimmung des Bitfehlerverhältnisses und dessen Grenzwerte benötigt. Der Nachweis kann dann durch messtechnische Untersuchungen erfolgen.

Der Grenzwert für die Fehlerrate gilt für das Gesamtsystem der Sicherheitsfunktion. Das Kommunikationssystem muss hierbei, als Teil des Gesamtsystems, entsprechend berücksichtigt werden, wobei die Norm IEC 61784-3 einen Richtwert von 1 % für den Anteil des Kommunikationssystems an der Fehlerrate nennt. Ein entsprechender Richtwert ist in Automobil-spezifischen Sicherheitsnormen dagegen nicht vorgegeben. Bei diesen steht die Fehlerrate für das Gesamtsystem im Vordergrund.

Zur Reduzierung der Fehlerrate bzw. zum Erreichen des Grenzwertes kann das betrachtete System um Absicherungsmechanismen erweitert werden. Neben einer redundanten Systemauslegung oder Maßnahmen zur Fehler-Diagnose können bei Kommunikationssystemen zudem technologie- und protokoll-spezifische Absicherungsmechanismen zum Einsatz kommen, die oft mit einem geringeren Aufwand umgesetzt werden können.

Somit sind die in Fahrzeugnetzwerken eingesetzten Technologie-Konzepte entsprechend der Einsatzbedingungen und der möglichen Fehlerursachen auszulegen und zu dimensionieren. Zur Verhinderung von Signalstörungen auf Grund von physikalischen Umgebungseinflüssen kann zum Beispiel eine geeignete Abschirmung des Kommunikationskanals erfolgen. Kostengünstiger und effektiver ist mitunter die Definition von Technologie-Eigenschaften auf der Bitübertragungsschicht und die Berücksichtigung von Design-Anforderungen zur Realisierung der Hardware-Architektur (z.B. beim Platinen-Layout oder Kommunikationskanal).

Auf den logischen Schichten einer Vernetzungsarchitektur lassen sich zudem Mechanismen zur Erkennung von Verfälschung, Verzögerung oder Verlust von Nachrichten implementieren. Fahrzeugbussysteme wie CAN-FD oder FlexRay aber auch Ethernet/IP-basierte Übertragungstechnologien bieten verschiedene Möglichkeiten zur Kommunikationsabsicherung. Weitere Mechanismen können zudem auf Applikationsebene zur Ende-zu-Ende Kommunikationsabsicherung implementiert werden. Standards wie AUTOSAR bieten hierzu geeignete Spezifikationen.

Da Absicherungsmechanismen keinen vollständigen Schutz garantieren können, muss für jeden Absicherungsmechanismus eine verbleibende Restfehlerrate bestimmt werden, die in die Fehlerrate des Gesamtsystems einfließt. Eine korrekte und validierte Funktionalität der Absicherungsmechanismen ist hierbei Voraussetzung bei der Ermittlung der Restfehlerrate.

Implementierung und experimentelle Erprobung eines Messkonzepts zur Bit-Fehlerbestimmung in Ethernet-basierten Fahrzeugnetzwerken

Im Projekt wurde ein Messkonzept zur Bestimmung des Bitfehlerverhältnisses auf dem Ethernet basierten Kommunikationskanal ausgearbeitet. Hierbei wurden unterschiedliche Methoden evaluiert, die eine messtechnische Ermittlung auf dem Übertragungskanal ermöglichen. Die damit verbundenen Anforderungen an den Messaufbau und das zu verwendende Messequipment wurden analysiert. Auf Basis dieser Untersuchungen wurde ein Messkonzept zur Bestimmung des Bitfehlerverhältnisses erarbeitet. Im weiteren Verlauf des Projekts wurde das Messkonzept in einem Versuchsaufbau umgesetzt und das Bitfehlerverhältnisses exemplarisch bestimmt. Hierbei wurden geeignete Möglichkeiten evaluiert, die Übertragungsqualität des Kanals zur Validierung des Messkonzepts gezielt zu beeinflussen.

Anhand der gewonnenen Ergebnisse wurde der in der Vorhabenbeschreibung definierte Key Performance Indikator KI5 (Datenfehler und -verluste) für die System-Integration evaluiert und mit dem Projekt-Zielwert von BER < 10⁻¹⁰ abgeglichen.

Für die betrachteten Automotive Ethernet Standards 100BASE-T1 und 1000BASE-T1 wurde ein Konzept zur Bestimmung und Verifizierung ihres Parameters für das Bitfehlerverhältnis entworfen. Eine wichtige Nebenbedingung war hier Berücksichtigung von Störquellen wie elektromagnetischer Strahlung sowie elektrische oder magnetische Wechselfelder (EMI), die in der Betriebsumgebung „Fahrzeug“ auftreten können. Dies sind z.B. induzierte Ströme, die auf einen Kommunikationskanal einwirken und insbesondere bei den hier genannten Standards Betrachtung finden, da hier das Ziel, den differentiellen Übertragungskanal ohne Abschirmung zu betreiben, verfolgt wird.

Zu diesem Zweck wurde ein Konzept erarbeitet, dem folgende Fragestellungen zu Grunde lagen:

- Generelle messtechnische Realisierung zur Ermittlung des Bitfehlerverhältnisses
- Identifizierung von Störeinflüssen den Übertragungskanal
- Messtechnische Realisierung mit definierten Störeinflüssen

Messtechnische Realisierung zur Bestimmung des Bitfehlerverhältnisses

Das Bitfehlerverhältnis kann für Kommunikationsstrecken durch das Senden von und Empfangen von Bitpattern und einem bitweisen Vergleich der gesendeten und empfangenen Daten ermittelt werden. Es werden die fehlerhaften Bits gezählt und ins Verhältnis gesetzt.

Bei Ethernet können zwei Möglichkeiten zur Bestimmung des Bitfehlerverhältnisses angewendet werden. Es kann neben dem schon beschriebenen bitweisen Vergleich, der die genaueste Abschätzung einer oberen Grenze liefert, auch über fehlerhafte Nachrichten ermittelt werden. Dieses Verfahren ist einfacher in der Umsetzung, da es sich der Tatsache bedient, fehlerhafte Nachrichten auf Hardwareebene zu zählen, um diese dann zu verwerfen, ohne das Vorhandensein einer aufwendigen Synchronisation, die bei einem bitweisen Vergleich anfiel. Voraussetzung hierfür ist die Annahme, dass in jeder gestörten Nachricht immer nur Einbitfehler vorkommen. Diese Annahme ermöglicht die Verbindung zwischen einem Bitfehler und einem Nachrichtenfehler, um von einem Nachrichtenfehlerverhältnis auf ein Bitfehlerverhältnis zu schließen. Auf dieser Grundlage wurde ein Messaufbau für die beiden Ethernet Standards 100BASE-T1 und 1000BASE-T1 erstellt. Hierzu wurde auf Ansatz gewählt, der eine Hybridlösung zwischen dem bitweisen und nachrichtenbasierten Bestimmungsverfahren implementiert. Damit konnte die quantitative Auflösung der Fehlerdetektion deutlich gesteigert werden. Für die Messung wurde wiederholt eine Nachricht über den Kommunikationskanal gesendet, dessen Nutzlast ein festgelegtes Bitmuster enthält. Hierdurch entsteht ein kontinuierlicher Bitstrom. Das entwickelte Konzept zur Bestimmung des Bitfehlerverhältnisses ist in Abbildung 8 dargestellt.

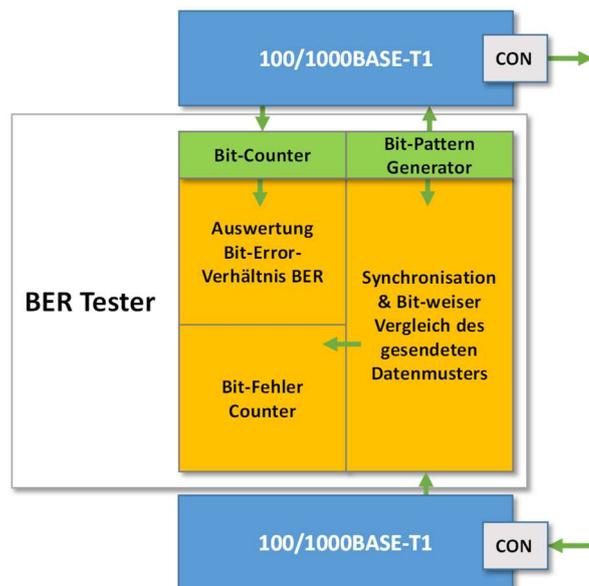


Abbildung 8: Konzept zur Bestimmung des Bitfehlerverhältnisses

Zur Evaluation des Messaufbaus wurde ein 24-stündiger Dauertest mit einem definierten Worst-Case-Channel durchgeführt. Damit wurde auch die Wahrscheinlichkeit eines intrinsischen Einflusses des Messsystems auf die Teststrecke erfasst. Des Weiteren wurde die Übertragungsstrecke über einen Richtkoppler mit einem differentiellen Rauschsignal beaufschlagt, um Fehler gezielt provozieren zu können. Für Vergleichsmessungen wurde der Bit Error Vergleich angewendet. Der Projektpartner b-plus stellte zur BER-Bestimmung von externen Komponenten einen Switch zur Verfügung, der mit 100/1000 BASE-T1 Ports ausgestattet war.

Bei der Entwicklung eines geeigneten Nachweiskonzeptes wurden die möglichen Störeinflüsse analysiert und in dem konzeptionellen Messaufbau umgesetzt.

Die Identifizierung der möglichen Störeinflüsse hängt dabei nicht zuletzt von den betrachteten Koppelmechanismen ab. Hier können zwei verschiedene Störquellen genannt werden.

1. Elektromagnetische Einstrahlung
2. Leitungsgebundene Störgrößen (induktive, kapazitive und galvanische Kopplung)

Die möglichen Störeinflüsse werden durch Testverfahren der einschlägigen Normen zur elektromagnetischen Verträglichkeit (EMV) behandelt.

Auf der oben genannten Betrachtungsgrundlage wurde ein konzeptioneller Entwurf einer Teststrecke erstellt, die für reale EMV-Testszenarien unter Laborbedingungen Kopplungsmechanismen der einzelnen Störungen auf die Übertragungsstrecke betrachtet. Bei dieser Betrachtung sollte der Einfluss von Störungen nur auf den Übertragungskanal selbst untersucht werden, der ein wichtiger Faktor bei der Ermittlung der zuvor erwähnten Restfehlerrate darstellt. Unter der Voraussetzung die Störgrößen ausschließlich auf der physikalischen Übertragungsleitung einzukoppeln, wurde ein Abschirmungskonzept konzipiert, welches den starken elektromagnetischen Feldstärken, die bei den Testverfahren zur Anwendung kommen, Stand hält. Abbildung 9 stellt das entwickelte Konzept zur Bestimmung des Bitfehlerverhältnisses unter EMV Einfluss dar.

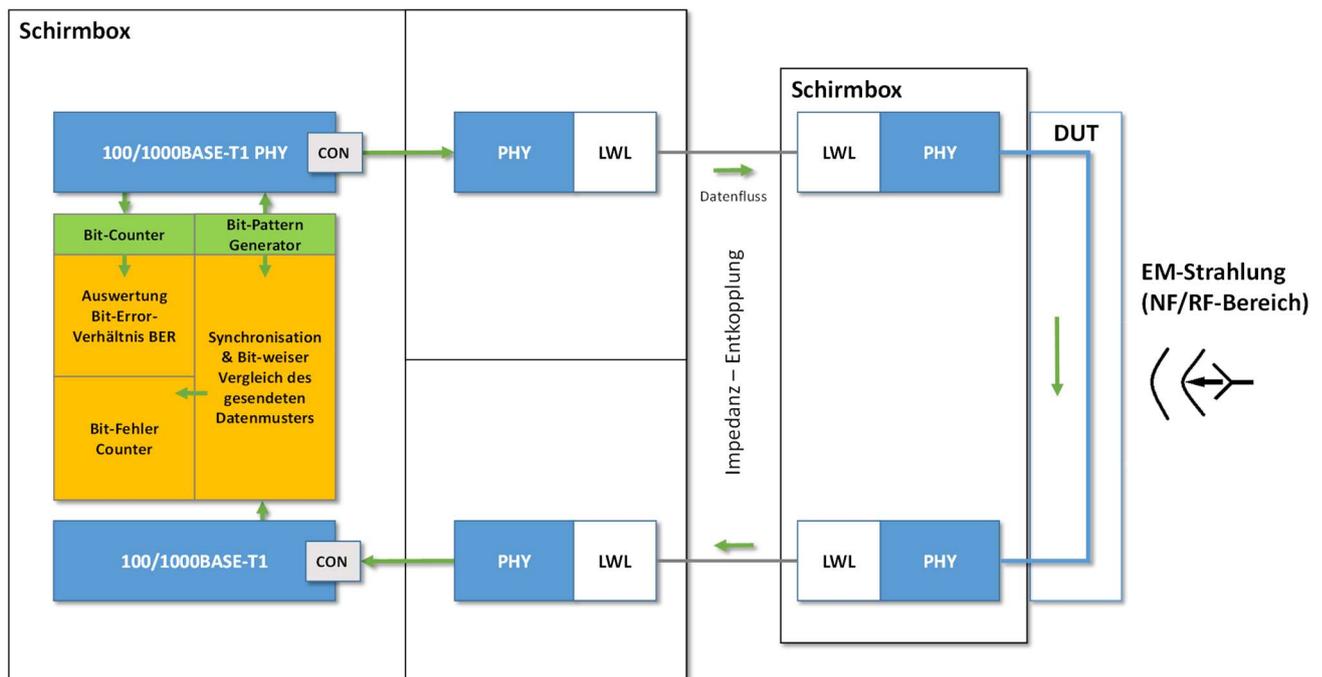


Abbildung 9: Konzept zur Bestimmung des Bitfehlerverhältnisses unter EMI

So können die elektronischen Komponenten vor direkter EM-Einstrahlung geschützt werden, um auszuschließen, dass auch Störungen direkt an der Elektronik generiert werden. Mithilfe des entwickelten Messkonzepts ist die Abschätzung des Bitfehlerverhältnisses für eine gegebene Kommunikationsstrecke möglich.

Anforderungen zur Absicherung der Kommunikationsarchitektur und Entwicklung eines Nachweiskonzepts

Zur Analyse der Vernetzungsanforderungen wurden verschiedene Vernetzungstechnologien untersucht. Dabei wurden verfügbare Informationen und Ergebnisse verschiedener Vernetzungstechnologien berücksichtigt, die zum Zeitpunkt der Projektdurchführung in Standardisierungsprojekten spezifiziert wurden. Folgende Auflistung gibt eine Übersicht zu den analysierten Technologien und Anforderungsspezifikationen.

- ISO/AWI 21111-1 Road vehicles -- In-vehicle Ethernet
- IEEE 100BASE-T1
- IEEE 1000BASE-T1
- IEEE 802.3 Multigig Automotive Ethernet
- IEEE 802.1AS
- OPEN Alliance Automotive Ethernet Anforderungsspezifikationen

Um die zuverlässige und fehlerfreie Funktionalität der Umfelderkennung des Fahrzeugs zu realisieren, wird eine zuverlässige und fehlerfreie Datenkommunikation vorausgesetzt. Um dieses zu gewährleisten, wurde ein Nachweiskonzept zur Validierung der Vernetzungsanforderungen für die einzelnen Komponenten der Vernetzungsarchitektur erarbeitet. Abbildung 10 zeigt die unterschiedlichen Schichten einer möglichen Kommunikationsarchitektur und Protokolle zum Serieneinsatz in automatisierten Fahrzeugen.

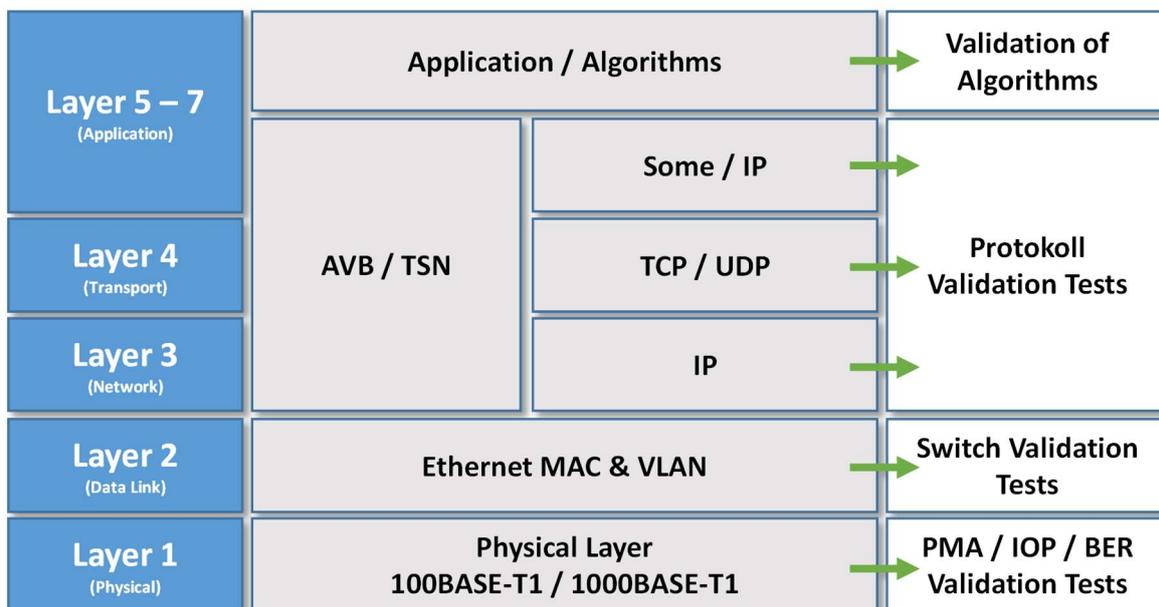


Abbildung 10: Schichtenmodell Kommunikationsarchitektur am Beispiel Ethernet

Zur Entwicklung des Nachweiskonzeptes wurden die einzelnen Übertragungsschichten analysiert und Vernetzungs- und Validierungsanforderungen definiert. Einzelne messtechnische Prüfungen wurden dann am Versuchsaufbau erprobt und validiert. Die erfolgten Arbeiten und Ergebnisse zur Entwicklung von Absicherungs- und

Validierungskonzepten der einzelnen Schichten wird im Folgenden zusammenfassend dargestellt.

Untersuchungen zur Signalintegrität und elektromagnetischen Verträglichkeit

Eine korrekte Übertragung der Daten auf physikalischer Ebene (Bitübertragungsschicht) ist essenziell. Die Übertragung findet sowohl für 100BASE-T1 als auch für 1000BASE-T1 über ein einfaches, verdrehtes Zweidraht-Kupferkabel im Hochfrequenzbereich (RF) statt und ist verschiedenen Störeinflüssen ausgesetzt, die im Fahrzeug auftreten können.

Um unter verschiedenen Störeinflüssen eine fehlerfreie Übertragung zu gewährleisten, sind die Signalintegrität und elektromagnetische Verträglichkeit (EMV) der eingesetzten Vernetzungskomponenten entscheidende Faktoren. Um diese zu gewährleisten müssen bestimmte elektrische Anforderungen erfüllt werden.

Im Rahmen der durchgeführten Arbeiten wurden Anforderungen an Signalintegrität und elektromagnetische Verträglichkeit beim Einsatz der Vernetzungstechnologien 100BASE-T1 und 1000BASE-T1 im Fahrzeugnetzwerk identifiziert.

Dabei wurden Anforderungen an RF- und S-Parameter-Grenzwerte sowie deren Nachweisverfahren für folgende Komponentengruppen analysiert:

- Verkabelung (Unshielded twisted pair)
- Konnektoren
- Gesamt-Kommunikationskanal
- Steuergeräte Hardware

Zur Untersuchung der definierten Anforderungen, Nachweisverfahren und eingesetzten Systemkomponenten wurden die konzipierten Messaufbauten prototypisch erstellt und an den 100BASE-T1 und 1000BASE-T1 Ports der Vernetzungskomponenten des AutoConstruct Versuchsträgers erprobt.

Hierzu wurden folgende Vorbereitungsarbeiten durchgeführt:

- Spezifikation der Anforderungen für RF- und S-Parameter auf Komponenten-Ebene
- Spezifikation der Messmethoden und des Testplans
- Spezifikation der Upper Tester Schnittstelle
- Entwurf und Implementierung der Adapterplatinen
- Erprobung und Vorbereitung der VNA & TDR Messaufbauten und Evaluierung der einsetzbaren Messmittel

Abbildung 11 zeigt schematisch die Messumgebung für Automotive Ethernet Komponenten am Beispiel eines Steuergeräts. Anforderungen an die Steuergeräte-Hardware zur Testdurchführung wurden analysiert und spezifiziert, um eine einheitliche und zuverlässige Testausführung und Testauswertung zu gewährleisten.

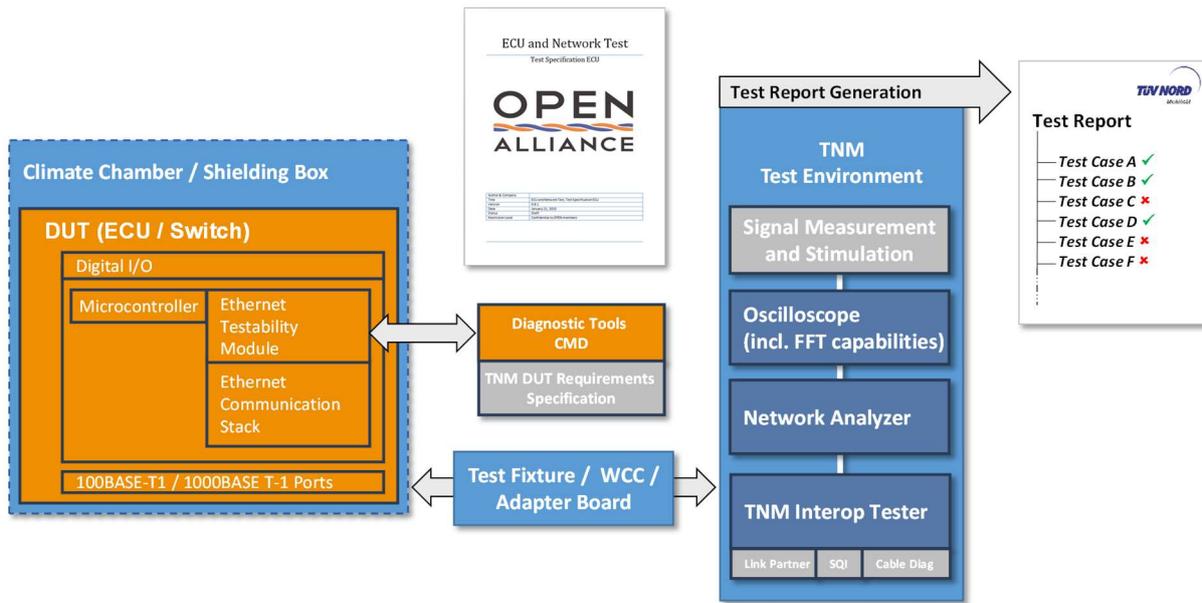


Abbildung 11: TNM Layer-1 Test Setup

Bei der Entwicklung und Evaluation dieses Messkonzeptes wurden im Rahmen der Ergebnisauswertung weitreichende Analysen hinsichtlich der Anforderungen an das Messkonzept durchgeführt, um eine zuverlässige Testaussage und Testabdeckung zu gewährleisten.

Anhand der durchgeführten Analysen wurde messtechnisch aufgezeigt, dass beim Einsatz von Kommunikationstechnologien mit hohen Datenraten im Gbps-Bereich nicht nur die technologischen Herausforderungen auf Produktebene enorm steigen. Es zeigt sich, dass sich bei der Validierung von RF- und S-Parametern der eingesetzten Systemkomponenten die Charakteristiken der eingesetzten Messmittel und der Messaufbauten sowie die Umgebungsbedingungen zum Zeitpunkt der Messdurchführung in hohem Maße auf die Messgenauigkeit und damit die Aussagekraft der Prüfergebnisse auswirken. Für verlässliche Aussagen über die Produkteigenschaften bestehen daher besondere Anforderungen an das Messkonzept und die Messumgebung. Im Hinblick auf diese Erkenntnisse wurden verschiedene Messmittel und Anpassungen des Messkonzeptes evaluiert, um einen für die Messpraxis der 100BASE-T1 und 1000BASE-T1 Technologien geeigneten und verlässlichen Prüfaufbau abzuleiten.

Aufgrund der steigenden Anforderungen an die Datenübertragungsrate wird die Technologie in Industriekonsortien schrittweise weiterentwickelt. So sind bereits höhere Datenraten in Richtung Multi-Gbps Ethernet in der Entwicklung. Damit werden zunächst Datenraten bis zu 10Gbps über Automotive Ethernet möglich sein. In speziellen Gremien wird weiterhin an noch höheren Übertragungsraten von 25 bis 50 Gbps gearbeitet. Die erweiterten Anforderungen an die Testumgebungen wurden hinsichtlich dieser Entwicklungen überprüft und notwendige Maßnahmen analysiert. Schon beim Übergang von 100 Mbps (100BASE-T1) auf 1 Gbps (1000BASE-T1) Datenübertragungsrate wurden in der vorangegangenen Entwicklung des Messkonzeptes erhöhte Anforderungen an das Messkonzept identifiziert.

Die weiterführenden Analysen haben bestätigt, dass sich die Anforderungen für die Validierung von Kommunikationstechnologien mit hohen Datenraten und Bandbreiten im Gigabit-Bereich gegenüber bestehenden Technologien nicht ohne wesentliche Anpassungen übertragen lassen. Hieraus ergeben sich besondere Herausforderungen, insbesondere im Hinblick auf die Absicherung und Validierung im Automobilbereich. Eine Weiterentwicklung der aufgebauten Testlösungen ist daher kontinuierlich notwendig, um die aktuellen Technologieentwicklungen abbilden zu können.

Aus den gewonnenen Erkenntnissen wurden notwendige Anforderungen und Handlungsempfehlungen abgeleitet, die sich zukünftig für die Validierung von Ethernet Technologien mit Multi-Gigabit Datenraten ergeben.

Untersuchungen der Interoperabilität auf der Bitübertragungsschicht

Neben den elektrischen Eigenschaften müssen Komponenten der Vernetzungsarchitektur eine einheitliche Implementierung der notwendigen Mechanismen der Bitübertragungsschicht aufweisen, um Interoperabilitätsprobleme zu vermeiden. Anforderung für eine Validierung der Interoperabilität unterschiedlich eingesetzter Komponenten wurden analysiert und Prüfanforderungen abgeleitet. Einer dieser Anforderungen ist beispielsweise, dass zwei Kommunikationskomponenten untereinander innerhalb einer fest definierten maximalen Zeitspanne einen Kommunikationslink aufbauen müssen.

Neben diesen Anforderungen an die generelle Funktionalität bei der Verwendung unterschiedlicher Kommunikationskomponenten sind für Automotive Ethernet grundlegende Diagnosefunktionalitäten wie das Detektieren von Kabelfehlern oder die Bestimmung der Signalqualität der Datenübertragung notwendig.

Zur automatisierten Prüfung wurde ein Hardwaretester konzipiert und am Beispiel des im AutoConstruct Versuchsträger eingesetzten Switch evaluiert. Hierzu wurden zur Validierung des Testaufbaus ebenfalls verschiedene Link Partner und Verkabelungen evaluiert. Abbildung 12 zeigt schematisch die Hardwarearchitektur des Messaufbaus.

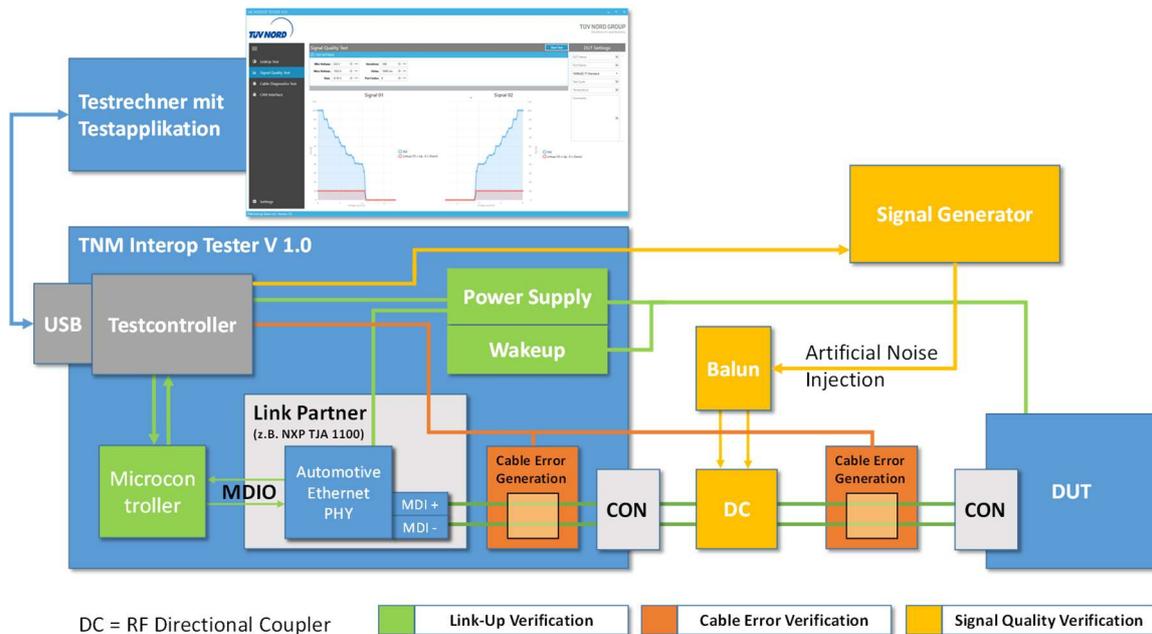


Abbildung 12: Test Architektur TNM Interoperabilitäts-Tester

Die Funktionsfähigkeit und Zuverlässigkeit der Kommunikation hängen maßgeblich auch von der Qualität des eingesetzten Kommunikationsmediums ab. Die Anforderungen der für die kabelgebundene Datenübertragung bei Automotive Ethernet verwendeten Kabel und Stecker wurden analysiert. Für die daraus abgeleiteten Testanforderungen wurden geeignete Prüfverfahren entwickelt und evaluiert.

Aus den entwickelten Prüfkonzepthen wurden Anforderungen an den zu verwendeten Übertragungskanal für die Durchführung von Interoperabilität Tests zwischen zwei Kommunikationsteilnehmern abgeleitet. Hierzu wurden Anforderungen an einen so genannten Worst-Case-Communication-Channel (WCC) analysiert und in experimentellen Untersuchungen an dem im Versuchsträger eingesetzten Switch evaluiert.

Technologieanalyse und Validierung von Protokoll-Eigenschaften

Auf den höher liegenden Schichten des Architekturmodells sind verschiedene Protokolle definiert, die den Transport der Daten zwischen den einzelnen Kommunikationsschnittstellen regeln. So müssen Datenbits beispielsweise in der Sicherungsschicht zunächst kodiert, dekodiert und strukturiert werden, um diese dann in Form von einzelnen Datenpaketen zwischen zwei verteilten Knoten im Fahrzeugnetzwerk übertragen zu können. Weiterhin müssen zur Sicherung des Datenaustauschs Verfahren zur Zugriffssteuerung auf das Medium und grundlegende Verfahren zur Flusskontrolle und Fehlerkorrektur definiert werden. Diese Mechanismen spielen vor allem bei der Analyse des Gesamtsystems hinsichtlich der Restfehlerrate und der Anforderungen an die funktionale Sicherheit eine entscheidende Rolle. Um die korrekte Funktionsweise zu gewährleisten, müssen diese Protokolle von allen Kommunikationsteilnehmern gleichermaßen implementiert und verstanden werden.

Relevante Anforderungen an höhere Protokollschichten wurden für ein serientaugliches, IP-basiertes Automotive Ethernet analysiert und Prüfanforderungen definiert. Abbildung 13 zeigt die Messumgebung zur Prüfung der Protokolle in höheren Schichten eines Steuergeräts. Mit Hilfe der Testumgebung können die identifizierten Anforderungen auf Steuergerät-Ebene validiert und verifiziert werden.

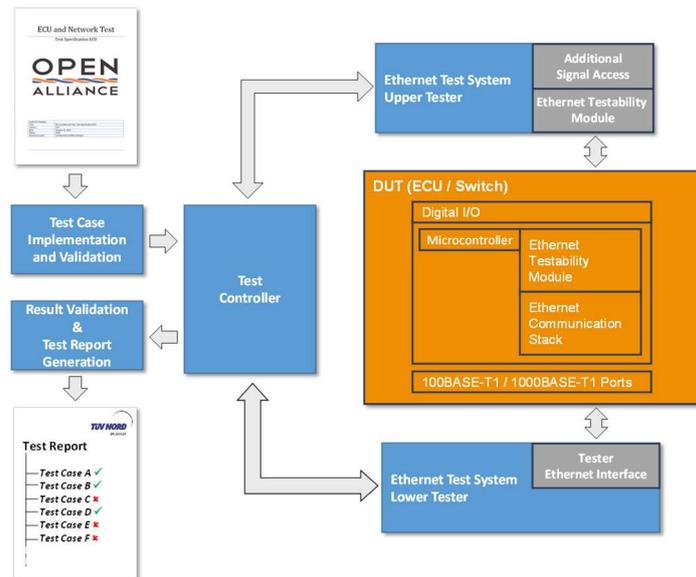


Abbildung 13: TNM Protocol Layer Test Setup

Zur Testdurchführung muss die zu testende Hardware bestimmte Schnittstellen und Anforderungen zur Verfügung stellen, um die Integration in die Testumgebung zu ermöglichen und um zuverlässige und aussagekräftige Testergebnisse zu erzielen. So muss die zu testende Hardware beispielsweise in einem sogenannten Ethernet Testability Module verschiedene Funktionen zur Teststeuerung bereitstellen. Die Anforderungen wurden analysiert und spezifiziert.

Die Prüfverfahren zur Konformitätsprüfung von Übertragungsprotokollen wie ARP, UDP, TCP/IP, IPv4 und SOME/IP wurden mithilfe der Testumgebung experimentell erprobt, um eine vollständige und zuverlässige Testabdeckung zu gewährleisten. Die Ergebnisse der durchgeführten Tests wurden analysiert, validiert und hinsichtlich ihrer Aussagekraft und Testabdeckung zur Absicherung der relevanten Protokollfunktionen bewertet.

Time Sensitive Network (TSN)

Für zeitkritische Steuerungs- und Regelungsanwendungen, wie diese im Automobilbereich existieren, kann ein im Ursprung als nicht deterministisch beschriebener Kommunikationsstandard, den zeitlichen Anforderungen alleine nicht genügen. Unterschiedliche Phänomene wie Kollisionen und Latenzzeiten stehen einer zeitgenauen Planbarkeit von Aktionen entgegen. Für viele Anwendungen ist ein deterministisches Verhalten jedoch eine zwingende Voraussetzung. Im Rahmen dieses Projekts wurde daher die OSI-Layer 2 Erweiterung nach IEEE 1588 Standard, der in AVB implementiert ist, auf seine

Synchronisationsgenauigkeit hin untersucht. AVB steht für Audio Video Bridging und besteht aus einem Konglomerat aus Standards, die in ihrer Gesamtheit ein zeitsensitives Verfahren darstellen, mit dessen Hilfe synchronisierte Abläufe innerhalb von Video- und Audio-Streams realisiert werden können. Damit erklärt sich ein Einsatz in sensorischen Kamerasystemen in zukünftigen Fahrzeugentwicklungen. Gegenstand der Untersuchung bildet hier das gPTP-Protokoll nach IEEE 802.1AS (Timing and Synchronization for Time-Sensitive Applications). Es wird verwendet, um in einem Netzwerk alle Taktgeber der Teilnehmerperipherie zu synchronisieren. Voraussetzung hierfür ist das Vorhandensein einer Echtzeituhr. Hierbei sind Switches ebenfalls miteingeschlossen, da sie die Synchronisation an andere Netzwerkteilnehmer oder -segmente weitergeben können. Durch einen in Hardware oder Software realisierten Zeitstempel ist es möglich zeitgenaue Abläufe zu planen und auszuführen, indem das Delay und die Abweichung aller sich im Netzwerk befindlichen Echtzeituhren durch die Master-Clock fortlaufend bestimmt und korrigiert wird. Auf diese Weise findet der Abgleich immer nur durch eine Punkt-zu-Punkt Verbindungen statt. Ziel der Untersuchung war die Bestimmung einer vorhandenen Restabweichung im synchronisierten Zustand, um aus den Daten, eine zeitkritische Bewertung der anfallenden Datenstreams der sensorischen Applikationen abzuschätzen.

AP 2: Datensammlung und Fahrzeugaufbau

Aufwand:

Continental (1 PM), CMORE (40 PM), b-plus (2 PM), TÜV-NORD (1 PM), Fraunhofer IAIS (1 PM)

Das Ergebnis des AP2 beinhaltet intelligent aufgenommene und gelabelte Daten von relevanten Szenarien zur Entwicklung und Absicherung der genannten Funktionen in den Zielsituationen.

Zur Umsetzung wurden die Architektur und Vernetzung aus AP1 und die Projektziele bzgl. Erkennungsattributen aus APO benötigt.

CMORE sah sich in dem Projekt in der Lage, den „*Cost-Sensitive-Learning*“ Ansatz zu einem Expertensystem im Bereich hochautomatisiertes Fahren weiter zu entwickeln. Baustellen sind unregelmäßig vorhanden und werden dabei während der Testfahrt bereits gezielt teilautomatisiert „Online“ markiert, bzw. wichtige Informationen „Online“ hinterlegt.

Derzeit werden Geschwindigkeitsbegrenzungsschilder zum Großteil von Hand gelabelt und kontrolliert. Herausforderung in diesem Projekt war die stark unterschiedliche Beschilderung und die Hinweise im Baustellenbereich, die nicht immer kreisförmig sind, genauso wie

mögliche Verdeckungen und Verschmutzung der Hinweise. CMORE hat zur Optimierung der Kosten und zur Beschleunigung des Labelprozesses für diesen speziellen Anwendungsfall einen neuen *Active-Learning* Ansatz entwickelt. Der neue Ansatz kann ebenso in anderen Spezialfällen für das hochautomatisierte Fahren angewendet werden. Um das AP-Ziel zu erreichen, waren folgende Teilarbeitspakete definiert:

- TP2.1: Konzept Fahrzeug
- TP2.2: Fahrzeugaufbau
- TP2.3: Einfahren von Daten
- TP2.4: Labeln - Entwicklung Methode und Tool
- TP2.5: Labeln von Daten

CMORE:

Detailierung TP 2.1 – Konzept Fahrzeug

Begonnen wurde hier mit Untersuchungen zum zu erwartendem Energieverbrauch des Versuchsträgers. Dazu wurden alle relevanten Komponenten systematisch erfasst und deren Energieverbrauch analysiert. Im Ergebnis wurde bspw. festgestellt, dass grundsätzlich eine Leistung von 1,5 kW bereitgestellt werden muss und dass bis zu 120 A im System fließen können. Außerdem wurde auch frühzeitig festgelegt, dass es hilfreich ist, das System für Testzwecke auch am 230-Volt-Netz betreiben zu können.

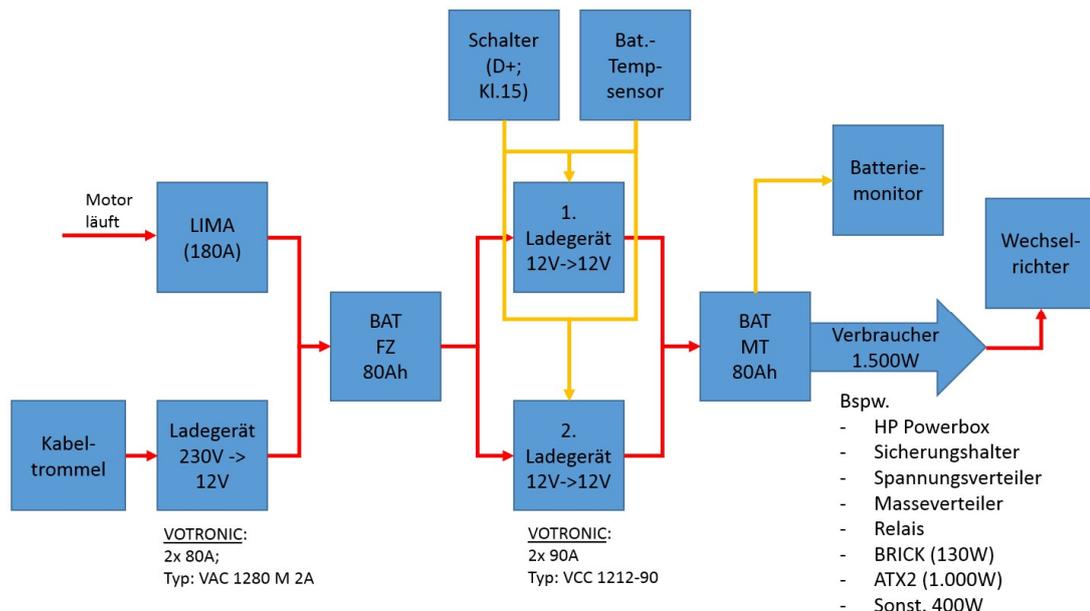


Abbildung 14: Blockschaltbild Powermanagement

Aus den grundlegenden Vorbetrachtungen wurde eine detaillierte Schaltung abgeleitet, welche im Weiteren die Basis für die technische Umsetzung darstellte.

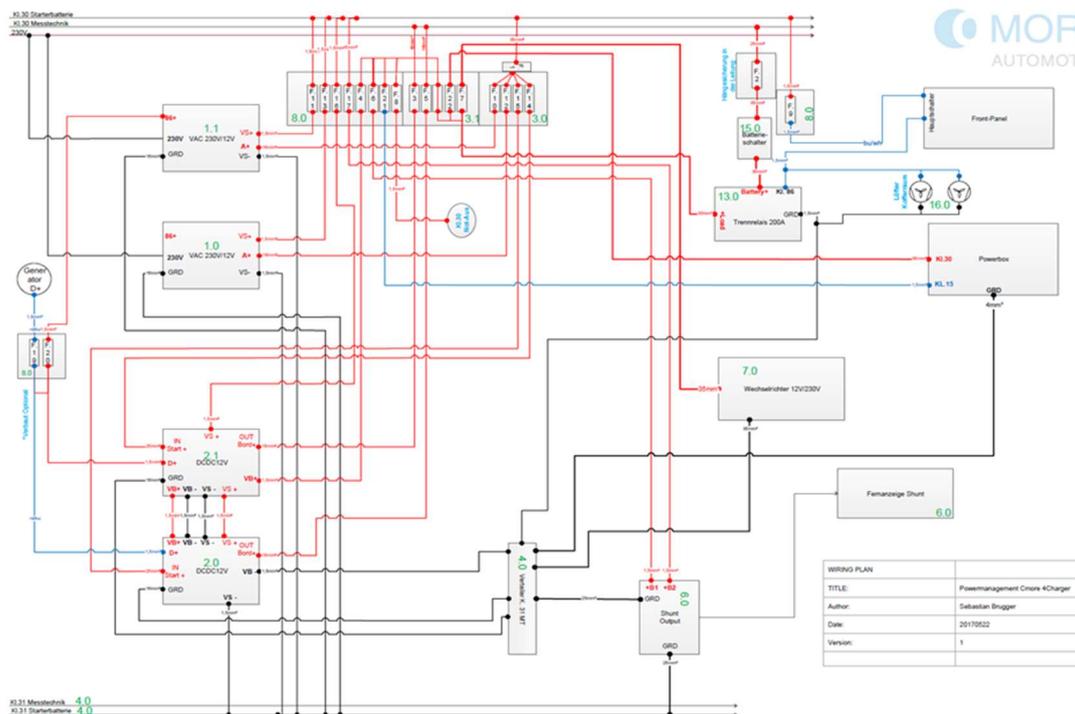


Abbildung 15: Schaltung Powermanagement

Detaillierung TP 2.2 – Fahrzeugaufbau

Mit diesen Arbeiten wurde etwas früher begonnen, um schneller projektrelevante Daten zur Verfügung zu haben. Der Versuchsträger, ein VW Passat Variant, wurde in enger Abstimmung mit den Projektpartnern beschafft und durch Umbauarbeiten gemäß des Vernetzungs- und Systemkonzeptes vorbereitet. Nach der Beschaffung des notwendigen Equipments, wie Sensoren und Messtechnikausrüstung, in enger Abstimmung mit den Projektpartnern, erfolgte der physische Aufbau.



Abbildung 16: Versuchsträger Ausbaustufe 1

Nach der Inbetriebnahme erfolgte die Kalibrierung der Surround-View- und Long-Range-Funktionen gemeinsam mit dem Partner Continental.



Abbildung 17: Inbetriebnahme des Versuchsträgers / Ausbaustufe 1



Abbildung 18: Versuchsträger AutoConstruct auf der Continental Kalibrierfläche in Memmingen

Nach der Anbindung der PODBOX (mit einer GPS-Antenne) in den Fahrzeugaufbau, war es möglich, während der Fahrt die genaue Position der Baustellen, sowie Schilder- und Spurenerkennung, die durch den Beifahrer getaggt wurden, direkt in das File der einzelnen Aufnahme zu speichern.



Abbildung 19: Fahrzeugaufbau VW Passat B8 Variant- Ausbaustufe 1

Ausbaustufe 2

Nach der Durchführung von ersten Testfahrten wurde gemeinsam mit den Verbundpartnern beschlossen, dass der Versuchsträger mit einer neuen Kamerageneration sowie aktualisierter und erweiterter Mess-/Rechentechnik ausgestattet wird.

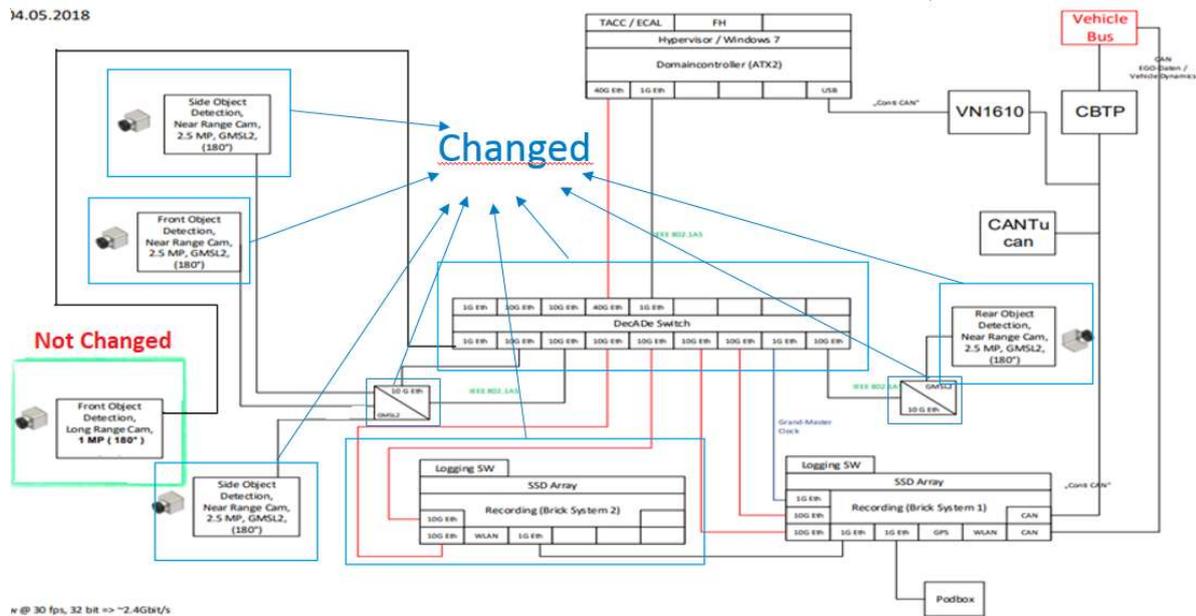


Abbildung 20: Änderungen – Ausbaustufe 2 Stand zum 31.12.2018

Es wurden u. a. folgende neue Komponenten verbaut:

- Kameras von Continental (Upgrade von 1 MP auf 2,5 MP)
- MDIs von b-plus (LVDS)
- Erweiterung des Speicherplatzes auf insgesamt 32 TB (2x16 TB)
- Switch von b-plus

Für die neuen Kameras mussten neue Halterungen entwickelt und angefertigt werden.

Für die exakte Platzierung der neuen Long Range Kamera wurde die Windschutzscheibe gescannt und mit Reverse Engineering die Halterung konstruiert.



Abbildung 21: Halterung Long Range Kamera

In der nachfolgenden Abbildung ist die aktuelle Kameraausstattung des Versuchsträgers dargestellt.

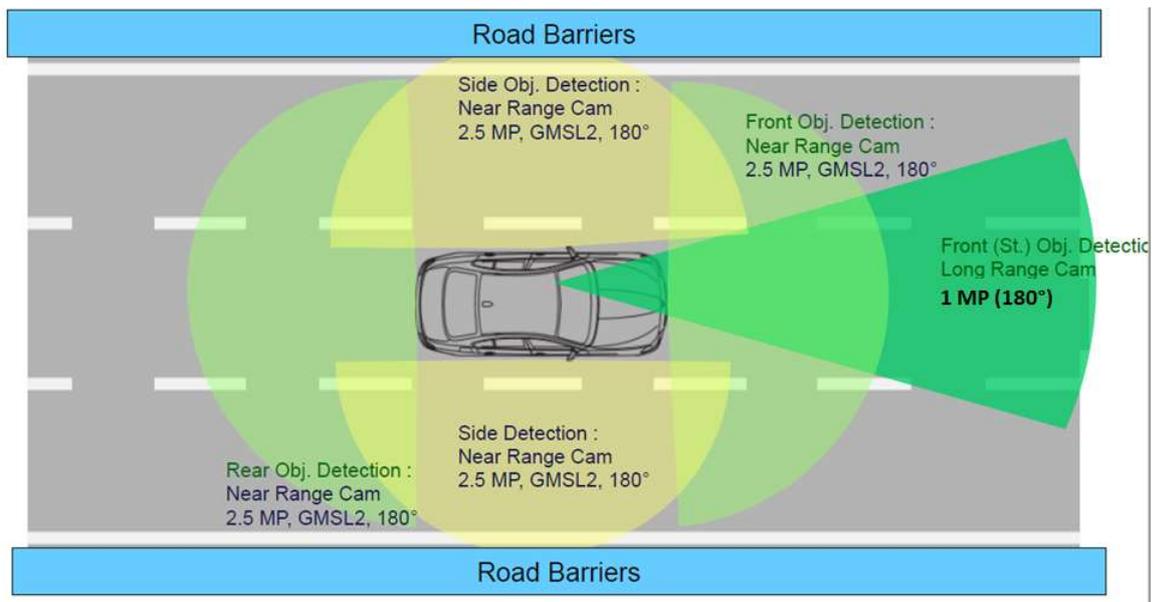


Abbildung 22: Übersicht Kameras Stand zum 31.12.2018

Zusätzlich wurden das OPUS Display zur Steuerung des Powermanagement mit Leuchtanzeigen für die laufenden Geräte, KVM Switch um zwischen den drei Computern zu wechseln und ein Splitter für die zwei Monitore (Fahrer und Beifahrer) aktualisiert.

Nach ausführlichen Diskussionen mit den Verbundpartnern und der Verfügbarkeit von neuen Komponenten erfolgte eine weitere Modifikation des Versuchsträgers.

DRAFT AutoConstruct EE-Architecture Ausbaustufe 2

04.03.2019

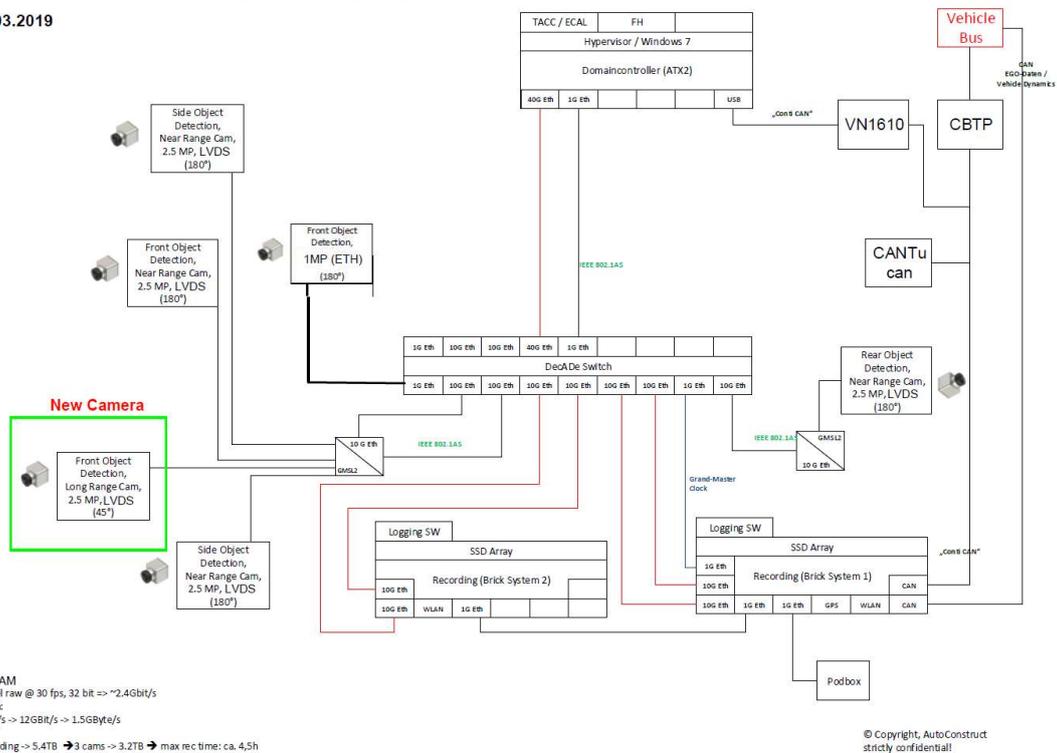


Abbildung 23: Änderungen – Ausbaustufe 2 Stand zum 30.06.2019

Im Einzelnen handelte es sich um folgende neu verbaute Komponenten:

- 2,5 MP-Kameras (Rear, Front, Side mirrors) mit neuer Software → Die bisher verbauten Kameras hatten Probleme mit der Kalibrierung und Überbelichtung
- Switch von b-plus wurde getauscht (Hardware hatte Funktionsprobleme)

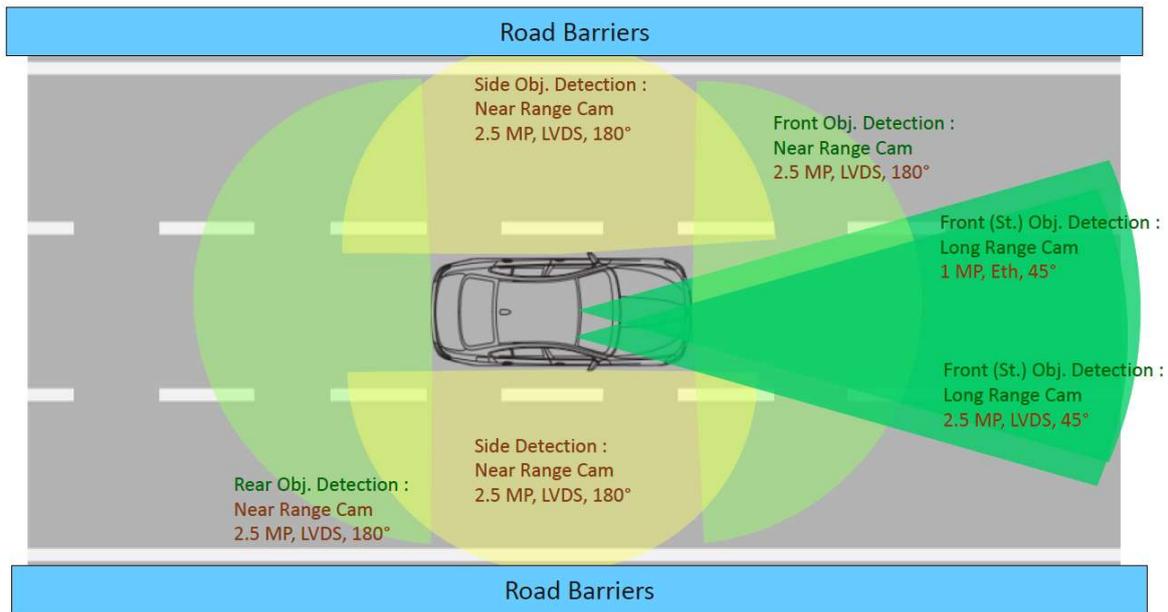


Abbildung 24: Übersicht Kameras Stand zum 30.06.2019

Die bisher offline betriebene Embedded-Hardware Nvidia Jetson Xavier wurde dann mit den weiterentwickelten Annotationsalgorithmen im 2. Halbjahr 2019 in den Versuchsträger eingebaut.

Detailierung TP 2.3 – Einfahren von Daten

Ausgehend vom oben beschriebenen konzeptionellen Fahrzeugaufbau wurde eine Erkundungsfahrt durchgeführt, um ein erstes Screening der angedachten Projektkonzepte und -arbeitsumgebung darzustellen und diente als Ausgangsbasis für die Abschätzungen der Annotierungs- und Dateneinfahrplanung.

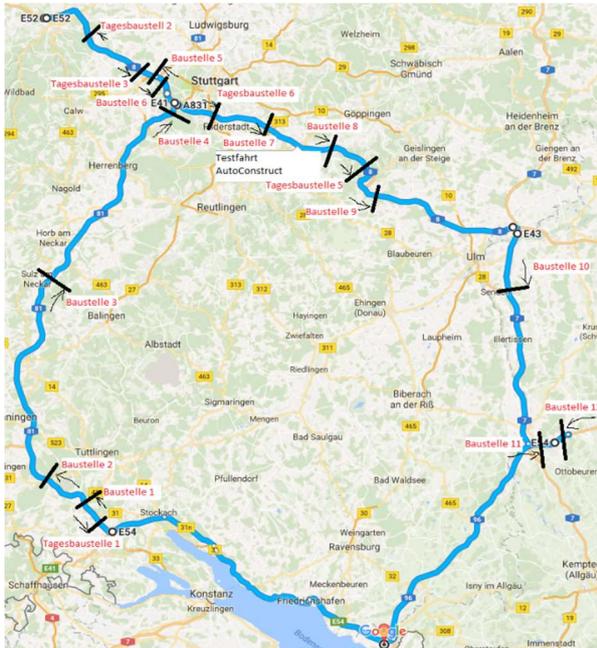


Abbildung 25: Erste Screening-Fahrt

Fahrzeit: 7h

Gefahrene Strecke: 490 km

Baustellen: 12

Baustellenstrecke gesamt (Ankündigung bis letztes Schild): 55,5 km

Baustellenstrecke gesamt (nur Baustelle): ca. 25 - 30 km

Durchschnittliche Strecke pro Baustelle: 2,3 km

Schilder gesamt: 238

Durchschnittliche Schilderanzahl pro Kilometer Baustelle: 7,5 (nur Baustelle)

4,3 (mit Ankündigungsstrecke)

Aufbauend auf den Teilergebnissen wurde nun eine systematische und zielorientierte weitere Bearbeitung aufgesetzt. U. a. wurde eine Infrastruktur für Datenspeicherung und Zugriff definiert. Zugrunde gelegt wurde dabei eine detaillierte Analyse der Datenraten der in Ausbaustufe 1 des Versuchsträgers verbauten Kameras.

Außerdem wurde eine Lösung zur automatisierten Fahrtenplanung erarbeitet. Das Sammeln von Entwicklungsdaten innerhalb von Autobahnbaustellen erfordert zwingend eine Planung der zu fahrenden Route. Traditionell wurde eine solche Aufgabe von einem CMORE Mitarbeiter übernommen. Dies ist jedoch zeit- und kostenintensiv. Zudem ist eine Routenänderung während einer begonnenen Testfahrt sehr umständlich, da erneut erst Baustellen in der Umgebung lokalisiert werden müssen.

Davon ausgehend wurde das Ziel gesetzt, eine Webanwendung zu erarbeiten, welche auf online verfügbaren Daten der Bundesanstalt für Straßenwesen (BASt) aufbaut.

Nur durch die Angabe von Start, Ziel bzw. Kilometerdistanz und Datum sollte damit eine Route erstellt werden können, die gezielt und effizient durch deutsche Autobahnbaustellen führt. Diese Anwendung sollte überall über das Internet erreichbar sein, um eine mögliche Neuberechnung oder Änderung der Route, auch während einer Testfahrt zu ermöglichen. Die erzeugte Route sollte auf mobilen Geräten in die Google Maps Navigations App übertragen werden können, um auf der Route entlang zu navigieren. Diese Aufgabe wurde flankiert durch eine Bachelorarbeit.

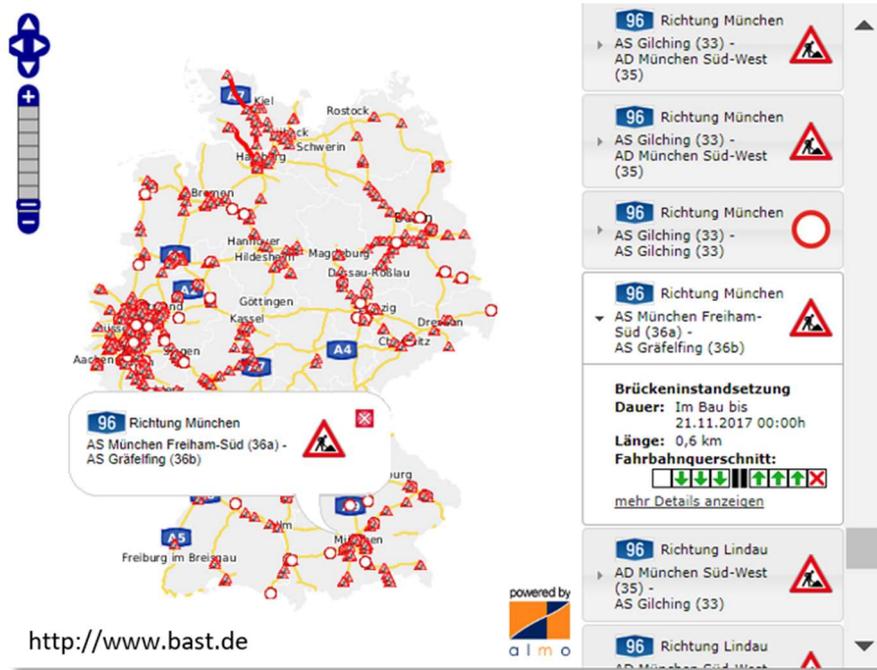


Abbildung 26: Online-Baustelleninformationen

Auf der Grundlage des erstellten Anforderungsprofils wurde dann ein Tool zur zielgerichteten (d. h. baustellen-affinen) Routenplanung entwickelt. Durch das Tool werden die Baustellendaten aus jedem Bundesland einzeln abgefragt, gefiltert und einheitlich in einer Datenbank zusammengefasst. Da jedes Bundesland seine Daten unterschiedlich pflegt und somit Lücken entstehen, mussten einige Werte selbst berechnet werden, um einheitliche Daten zu verwenden. Die Daten in der Datenbank werden einmal täglich automatisch aktualisiert, um für die Routenerstellung die neusten Daten zu verwenden.

Für die Routenplanung stehen zwei Varianten zur Verfügung. Bei der Variante Destination wird durch die Nutzereingabe von Start, Ziel, Datum und gegebenenfalls der Option gesperrte Straßen miteinzubeziehen eine Route ermittelt. Diese Route beginnt am gewünschten Startpunkt und führt zum gewünschten Zielort. Die Strecke verläuft dabei durch die maximal 11 längsten Baustellen, die zwischen diesen beiden Punkten liegen. Die ermittelte Route wird dem Nutzer auf dem Endgerät auf einer Karte visualisiert. Zudem werden Informationen wie die Gesamtdauer und Gesamtdistanz der Route sowie die Dauer und Distanz innerhalb von Baustellen angezeigt.

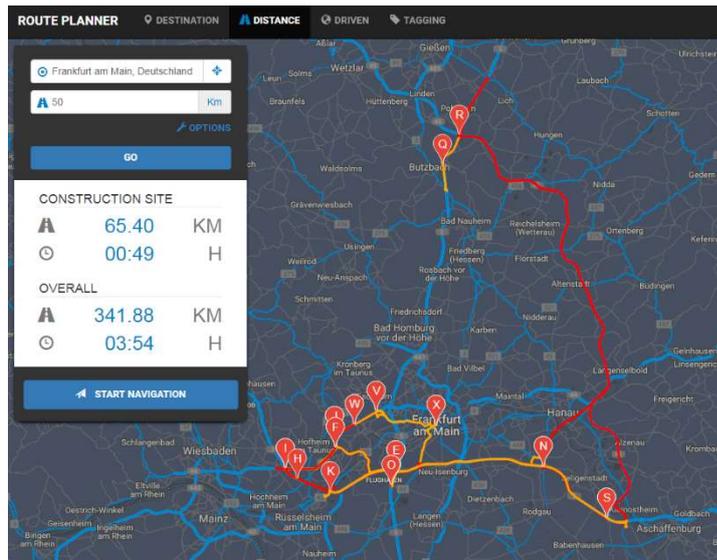


Abbildung 27: Routenberechnung nach dem Ansatz "Destination"

Bei der Variante „Distance“ wird durch die Nutzereingabe von Start, Kilometerangabe, Datum und gegebenenfalls der Option gesperrte Straßen miteinzubeziehen eine Route ermittelt. Diese Route beginnt und endet wieder am vorgegebenen Startpunkt. Anhand der angegebenen Kilometerzahl wird eine Route erstellt, mit der sich durch maximal 11 Baustellen die angegebene Kilometerzahl abdecken lässt. Gibt ein Nutzer beispielsweise 80 Kilometer an, werden die maximal 11 nächstliegenden Baustellen ausgewählt, die in der Summe mindestens 80 Kilometer abdecken.

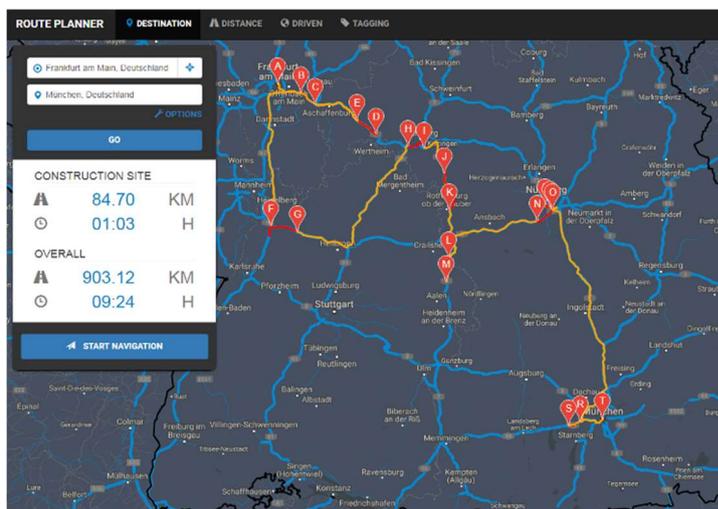


Abbildung 28: Routenberechnung nach dem Ansatz „Distance“

Die Baustellen werden auf der visualisierten Route rot hervorgehoben. Ist es notwendig bei einer der beiden Optionen noch eine Anpassung der Route vorzunehmen, bevor man die Route in eine Navigations-App überträgt, kann dies durch Verschiebung der Kartenmarkierungen (Map Marker) passieren. Um die Anwendung auch unterwegs nutzen zu können, wurde die Entwicklung in einem Responsive-Design ausgeführt und kann somit auf verschiedensten Geräten (Tablets, Smartphones etc.) optimiert bedient werden. Die nachfolgende Abbildung zeigt Beispiele für mobile Ansichten des Systems.

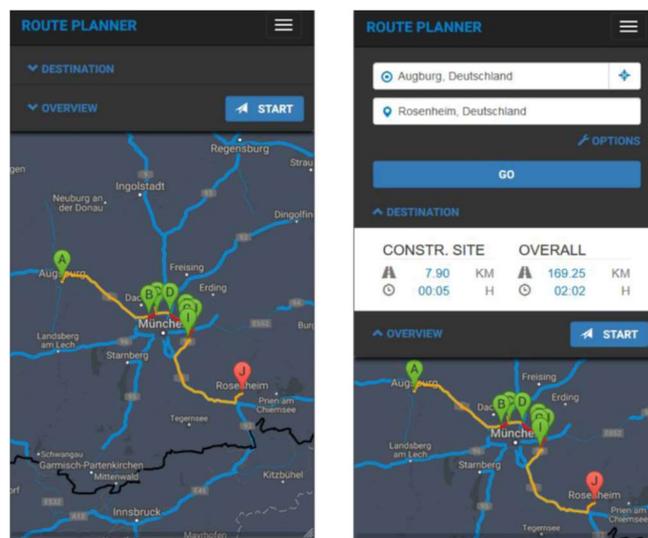


Abbildung 29: mobile Ansicht des Systems

Außerdem lassen sich bereits gefahrene Baustellen (deren Koordinaten durch eine im Fahrzeug integrierte GPS-Antenne empfangen und gespeichert werden) auf einer Landkarte darstellen.

Auf dieser Basis wurden im 1. Halbjahr 2018 insgesamt 17.541 km gefahren; davon 2.890 km in der Baustelle. Es wurden von den Fahrern insgesamt mehr als 10.000 baustellenrelevante Schilder und Spuren getaggt (gezählt).

Nach Auswertung der Ergebnisse wurde beschlossen, das Tool zur Unterstützung der Routenplanung nochmals zu optimieren. In der bisherigen Version wurden die Baustelleninformationen von einer MDM-Plattform zur Verfügung gestellt und das Routenplanungs-Tool griff tagesaktuell darauf zu. Nach dem Planungsvorgang wurde die Wegbeschreibung mit Hilfe von Google Maps an den Fahrer übermittelt.

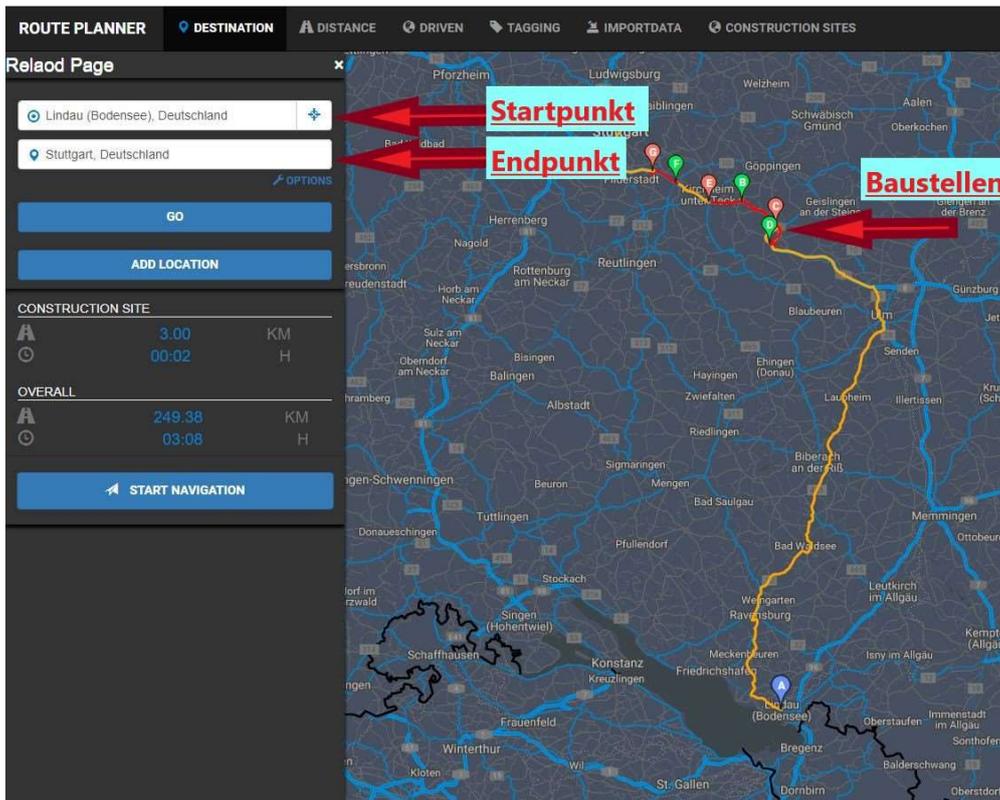


Abbildung 30: Übersicht - Basis Routenplaner

Da Google Maps maximal 22 Orte zulässt, konnten mit dem System in Summe bis zu 11 Baustellen zwischen den Endpunkten eingegeben werden. Nach der bisherigen Lösung wurden die kürzesten Baustellen mit dem Tool abgebrochen und gelöscht, nur die 11 längsten Baustellen auf der Route wurden angezeigt.

Um jede Baustelle einbeziehen zu können, verkürzt das verbesserte Tool die Entfernung und schlägt einen neuen Endpunkt möglichst nahe dem eingegebenen ursprünglichen Standort vor.

Es ist nun möglich, Zwischenziele einzugeben, z. B. Lindau nach München über Ulm.

Weiterhin wurde in das Tool eine Option zum Ausschließen von bereits gefahrenen Baustellen implementiert. Es besteht nun die Möglichkeit, die bereits gefahrenen Baustellen in der Route über ein bestimmtes Zeitintervall auszugrenzen. Eine Checkbox ermöglicht diese Eingabe. Wenn das Kontrollkästchen aktiviert ist, kann das Start- und Enddatum ausgewählt werden. Alle Baustellen, die in diesem Zeitraum gefahren wurden, werden nicht berücksichtigt.

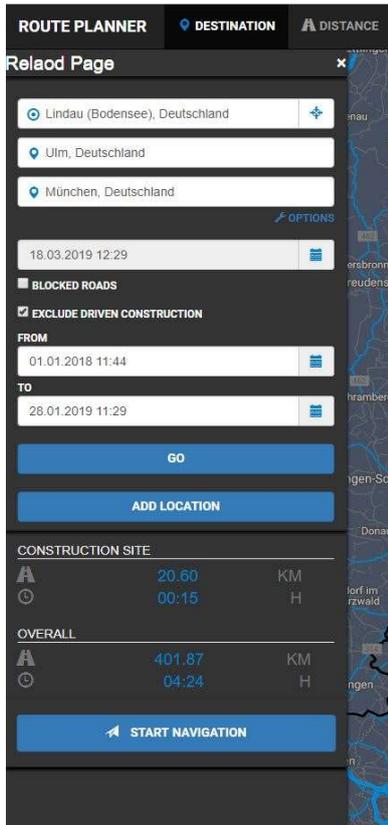


Abbildung 31: Filtern von bereits gefahrenen Baustellen

Beginn und Ende der Baustelle sind abhängig von der Fahrtrichtung. Sie werden unterschiedlich markiert, um einen besseren Überblick zu erhalten

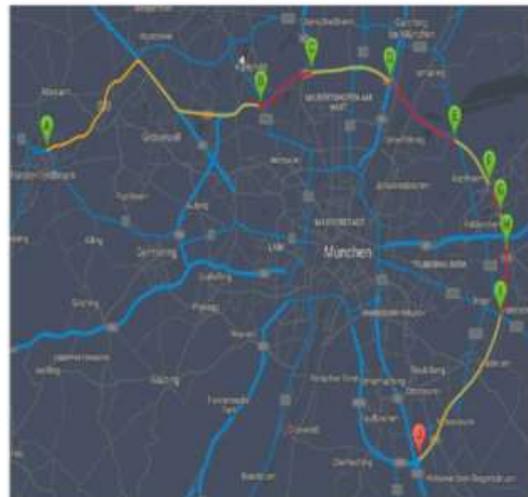
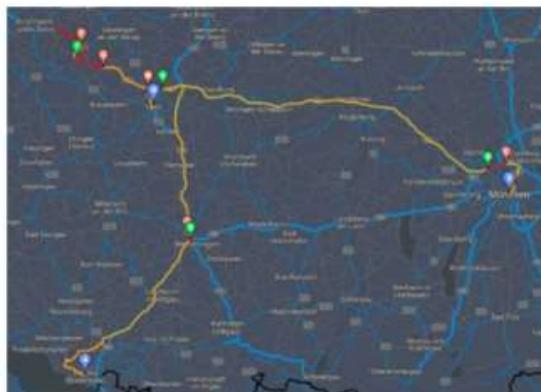


Abbildung 32: Fahrtrichtung der Baustellen wird über farbige Flags erkennbar

Des Weiteren werden verfügbare Baustellen im Tool nach Fahrtrichtung angezeigt.



Abbildung 33: Nicht gefahrene Baustellen



Abbildung 34: Gefahrene Baustellen



Abbildung 35: Auswertung der eingefahrenen Daten

Unter Einsatz des optimierten Tools zur Unterstützung der Routenplanung wurden in 2019 an 16 Tagen weitere 6100 km gefahren und dabei 1600 deutsche Autobahnkilometer aufgenommen. Bei den Testfahrten zur Datenakquise und Validierung konnte nachgewiesen werden, dass die Technik der Ausbaustufe 2 in der neuesten Version grundsätzlich funktioniert.

Detailierung TP 2.4 – Labeln – Entwicklung von Methode und Tool

Annotationsprozess

Für den Prozess der Datenannotation wurden mehrere Schritte durchlaufen. Bereits während dem Einfahren und Sammeln der Daten wurden Markierungen zu den relevanten Verkehrszeichen und Verkehrsereignissen platziert. Für das Pre-Tagging wurde während der Fahrt das CMORE PODBOX-Produkt eingesetzt. Diese vormarkierten Daten wurden verwendet, um die Aufzeichnungen nach verschiedenen Bedingungen (z. B. Tag, Nacht, Baustelle, Geschwindigkeitsbeschränkung, ...) herauszufiltern.

Abbildung 36: Pre-Tagging mit CMORE-PODBOX

Die Daten wurden aus den gefilterten Aufnahmen extrahiert und nur bestimmte Bilder für die manuelle Beschriftung ausgewählt. Die ausgewählten Bilder stammen von Baustellenaufnahmen und beinhalten entsprechend der Spezifikation relevante Verkehrsschilder.

Die so ausgewählten Bilder wurden mit dem CMORE Annotationstool 'C.LABEL' zunächst manuell annotiert und zum Training von Deep-Learning-Algorithmen zur Verkehrszeichenerkennung und -lokalisierung verwendet. Nach dem Training wurden diese Modelle / Algorithmen an neuen Testbildern evaluiert, um zu überprüfen, wie gut der Algorithmus bei der automatischen Erkennung von Verkehrszeichen ist. Basierend auf den Bewertungsergebnissen wurde der Prozess entweder beendet oder eine weitere Iteration aus Datenerfassung, Bildauswahl, manueller Annotation, Training, Test und Evaluierung

durchlaufen. Die vollständige Übersicht des Annotationsprozesses ist in der folgenden Abbildung dargestellt.

Der Iterationsprozess, der sehr viel Zeit und Aufwand erfordert, wurde während des Projektes zweimal durchgeführt.



Abbildung 37: Annotationsprozess

Der Annotationsprozess bei der ersten Iteration wurde wie folgt umgesetzt:

- Erstellung einer Annotationspezifikation
- Tausende Kilometer wurden eingefahren und die Aufnahmen in zahlreichen brec recordings abgelegt.
- Online Pre-Tagging wurde für definierte Ereignisse angewendet (Lichtverhältnisse, Baustellentyp, Anzahl der Fahrstreifen, baustellenrelevante Verkehrsschilder, Zusatzzeichen, Spurerkennungen, etc...).
- Ein Trainingssatz von 10.000 manuell annotierten Bildern wurde erstellt.
- Jedem annotierten Zeichen wurde eine Bounding Box und eine Klasse, basierend auf der Spezifikation, zugewiesen.
- Die Annotation wurde für die Aufnahmen der Long Range Front Kamera umgesetzt.
- Die Ergebnisse wurden in einem abgestimmten json-Format gespeichert.
- Die Leistung wurde anhand eines Datensatzes von 1656 Verkehrszeichen bewertet.

Die erzielten Ergebnisse:

- 83 % der Verkehrszeichen wurden korrekt lokalisiert und klassifiziert (1377 von 1656).
- 7 % der Verkehrszeichen wurden falsch klassifiziert (Verwechslung zwischen Überleitung und Verschwenkung).
- 10 % der Verkehrszeichen wurden entweder korrekt klassifiziert, aber die zugehörige Bounding Box passte nicht zum Schild (die Übereinstimmung ist weniger als 60 % im Vergleich zu den manuell annotierten Bounding Boxen) oder wurden gar nicht erkannt.

Annotationsprozess – Zweite Iteration

Für diese Iteration wurden weitere Module entwickelt, um die in der ersten Iteration gefundenen Einschränkungen zu überwinden. Zu diesen Einschränkungen gehört die Erkennung von Verkehrszeichen, die an LKWs angebracht sind, als echte Verkehrszeichen, und es gab einige Lücken zwischen den Erkennungen entlang einer Aufnahme.

Folgende Maßnahmen wurden zur Verbesserung umgesetzt:

- Der Algorithmus wurde mit weiteren Aufnahmen trainiert.
- Weitere Bilder wurden für die manuelle Annotation ausgewählt.
- Ein weiterer Datensatz mit 15.000 manuell annotierten Bildern wurde für das Training erstellt.
- Es wurde ein weiteres Modul für die Erkennung von Fahrzeugen entwickelt.
- Um die Ergebnisse der Verkehrszeichendetektion und der Fahrzeugdetektion zu verschmelzen und um damit die an Lastwagen angebrachten Schilder zu eliminieren, wurde ein Verfeinerungsmodul entwickelt.

Die erzielten Ergebnisse nach der Entwicklungserweiterung sind wie folgt:

- 89.4 % (zuvor 83 %) der Verkehrszeichen wurden korrekt lokalisiert und klassifiziert (1482 von 1656).
- 3.8 % (zuvor 7 %) der Verkehrszeichen wurden falsch klassifiziert (Verwirrung zwischen Überleitung und Verschwenkung).
- 6.8 % (zuvor 10 %) der Verkehrszeichen wurden entweder korrekt klassifiziert, aber die zugehörige Bounding Box passt nicht zum Schild (die Übereinstimmung ist weniger als 60 % im Vergleich zu den manuell annotierten Bounding Boxen) oder wurden gar nicht erkannt.

Detaillierte Ergebnisse der automatisierten Annotation:

Die untenstehende Verwechslungsmatrix zeigt die Verteilung der Detektionen aller Kategorien von Verkehrszeichen. Aus der Abbildung ist ersichtlich, dass sich alle Erkennungen entlang der Diagonale der Matrix konzentrieren, was eine hohe Erkennungsrate in fast allen Kategorien bedeutet. Die durchschnittliche Erkennungsrate aller im Testdatensatz enthaltenen Klassen liegt bei rund 89 Prozent. Die meisten Verwirrungen sind auf sehr ähnliche Klassen zurückzuführen (z. B. Überleitung- bzw. Verschwenkungstafeln), die für den entwickelten Deep-Learning-Algorithmus eine große Herausforderung bei allen Bedingungen darstellen.

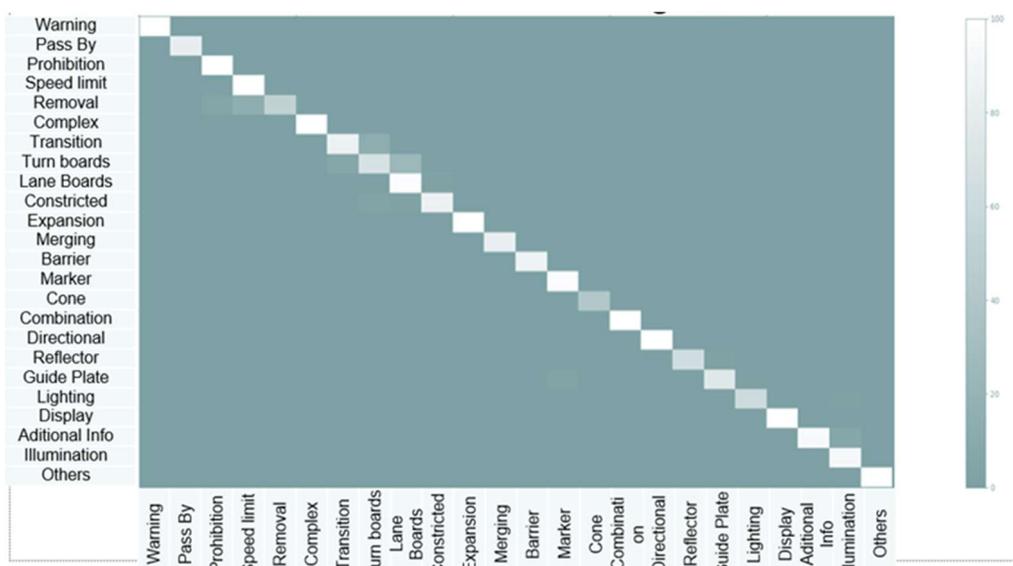


Abbildung 38: Verwechslungsmatrix Baustellenverkehrszeichen

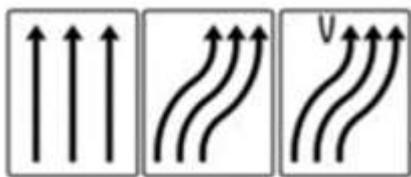


Abbildung 39: Verschwenkungstafeln

Hier ein Beispiel der automatisierten Ergebnisse, bei denen alle erforderlichen Schilder korrekt klassifiziert wurden und die Bounding-Boxen eng an den Schildern anliegen.

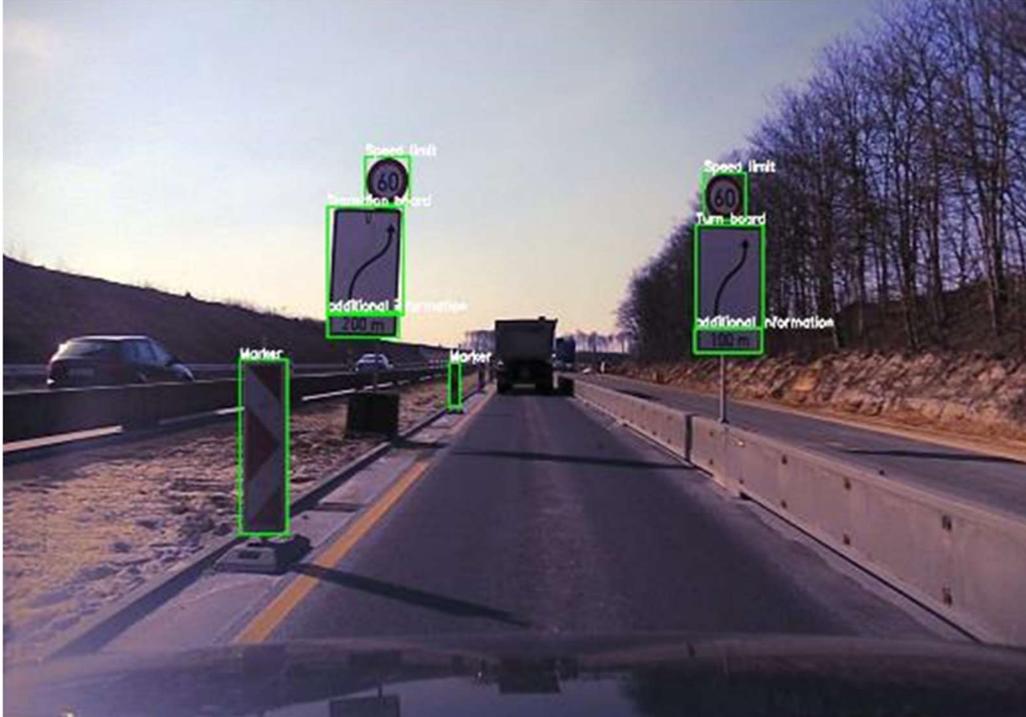


Abbildung 40: Korrekt klassifizierte Baustellenschilder mit enganliegenden Bounding-Boxen

Einbindung des Algorithmus in ein Embedded-Gerät

Der Algorithmus wurde so optimiert, dass er im Fahrzeug auf einem Nvidia Jetson AGX Xavier Entwicklungs-Toolkit lauffähig ist. Das Gerät ist ein Computer mit künstlicher Intelligenz (KI), der mit einer GPU mit 512 cores und 16 GB Ram ausgestattet ist und die Leistung eines GPU-Servers in einem kleinen Embedded-Modul liefern kann. Eine weitere Algorithmus-Optimierung erfolgte mit TensorRT, einer Bibliothek, die die Inferenzzeit auf Nvidia-GPUs beschleunigt. Die Verwendung dieser Bibliothek ermöglichte es, den Algorithmus auf dem Embedded-Gerät mit etwa 30 Bildern pro Sekunde laufen zu lassen, was ausreichte, um die Kamerastreams im Fahrzeug in Echtzeit zu verarbeiten.

Automatic tagging tool

Da die Lösung nun im Versuchsträger Kamera-Streams verarbeiten konnte, wurde dieser Ansatz zur Weiterentwicklung des manuellen Tagging-Produkts, der PODBOX, verwendet. In der Vergangenheit wurde mit Hilfe der PODBOX vom Benutzer Tags bzw. Markierungen während der Fahrt manuell eingegeben. Diese Tags sind Orientierungspunkte zur Unterstützung bei der Datenfilterung, um interessante Szenarien für Baustellen zu extrahieren. Durch diese Tags kann z. B. zwischen Tag- und Nachtaufnahmen, Baustellen sowie Autobahn- und Stadtaufnahmen unterschieden werden.

Darüber hinaus kann der Benutzer das Vorhandensein bestimmter Verkehrszeichen markieren. Damit wird bei der Weiterbearbeitung das Auffinden bestimmter Ereignisse erleichtert. Die manuelle Markierung von Verkehrszeichen ist jedoch sehr unübersichtlich und erfordert einen hohen Aufwand und die Konzentration des Beifahrers. So spart die Anwendung des Algorithmus im Versuchsträger Zeit und Mühe bei dem Setzen der Tags. Daher wurde ein einfaches automatisches Tagging-Tool mit Unterstützung des portierten Algorithmus auf dem Nvidia AGX-Gerät entwickelt.

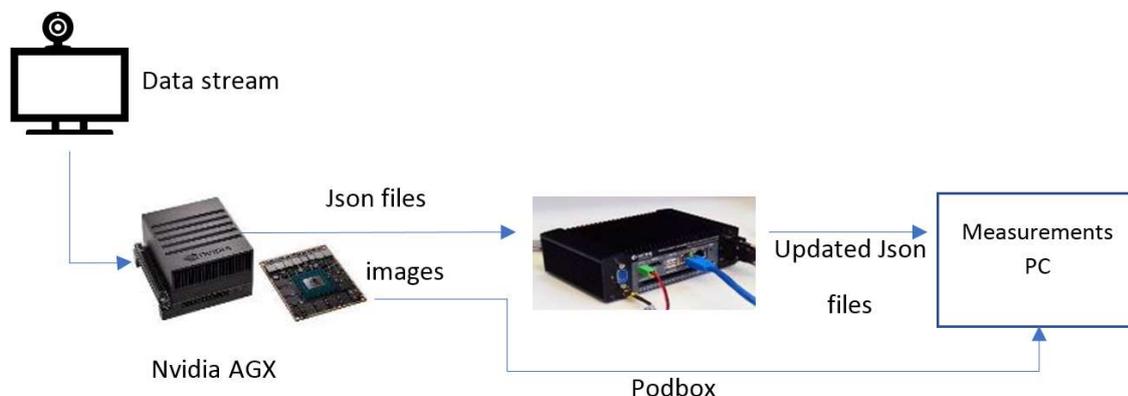


Abbildung 41: Darstellung automatisches Online-Tagging

Beim automatischen Tagging werden folgende Schritte durchgeführt:

- Ein Datenstrom wird von der Kamera erfasst und an das Nvidia AGX Embedded Gerät gesendet.
- Sobald die Daten von Nvidia AGX empfangen werden, werden sie von dem optimierten Algorithmus zur Verkehrszeichenerkennung verarbeitet.
- Die Ausgabe des Algorithmus ist ein Satz von erkannten Verkehrszeichenklassen, der als automatisch generierte Tags interpretiert wird.
- Diese Tags werden über Ethernet im json-Format an das PODBOX-Gerät gesendet, das die Möglichkeit hat, diese Tags drahtlos über eine LTE-Verbindung zu übertragen.
- Die von der PODBOX empfangenen Tags werden in anderen Formaten neu strukturiert und an einen Server gesendet.
- Die Bilder werden von Nvidia AGX direkt an den Server geschickt. Dieser enthält somit alle gesammelten Daten.

Detailierung TP 2.5 – Labeln von Daten

Diese Arbeiten wurden in engem Zusammenspiel mit AP 2.4 durchgeführt.

Insgesamt wurden den Projektpartnern je über 1 Mio. automatisiert annotierte Bilder zur Verfügung gestellt.

AP 3: Sensorik & Signalerkennung

Aufwand:

Continental (60 PM), CMORE (2 PM), Fraunhofer IAIS (56 PM)

Die Aufgabe dieses Arbeitspaketes war die Erforschung und die Entwicklung von robusten Algorithmen zur Umfelderkennung in Baustellensituationen. Als Sensorik wurden vorrangig Farbkameras eingesetzt: Eine Frontkamera mit mindestens 1 Megapixel Auflösung und mehrere Surround View-Nahbereichskameras mit mindestens 1 Megapixel Auflösung. Andere Sensoren, wie Radar oder Lidar spielten nur eine untergeordnete Rolle.

Es sollten Verfahren zur Detektion von Objekten entwickelt werden, die im Baustellenbereich relevant sind. Es handelte sich hierbei um: Leitbaken, Leitkegel, Schutzwände und farbige Fahrbahnmarkierungen. Anhand von Verkehrszeichen sollte die Spurbreitenbegrenzung erkannt und mit den Außenmaßen des Fahrzeugs verglichen werden.

Im Umgebungsbereich der Baustellen wurden mit Verfahren zur Erkennung komplexer Verkehrszeichen Hinweisschilder detektiert, und dem Fahrer der relevante Bildausschnitt auf einem Monitor visualisiert. Da die Bandbreite der möglichen Hinweisschilder sehr groß ist und von Spurführungszeichen bis zu Umleitungsempfehlungen reichen kann, wurden nur die Spurführungszeichen einer weiteren inhaltlichen Analyse unterzogen.

Das Arbeitspaket war in zwei Phasen geplant: Nach der ersten Entwicklungsphase wurden die Verfahren im Gesamtsystem des Fahrzeugs evaluiert. Anschließend wurden die Anforderungen für die zweite Entwicklungsphase angepasst. Dementsprechend wurden die Teilarbeitspakete wie folgt strukturiert:

- TP3.1: Erkennung von Baustellen-Ankündigungs-Verkehrszeichen inkl. Zusatzzeichen (Hauptaufwand Continental)
- TP3.2: Erkennung von auf Anhänger montierten komplexen Hinweisschildern, inkl. der elektronischen Fahrtrichtungsweiser, Teil 1 und Teil 2 (Hauptaufwand Continental)
- TP3.3: Detektion von Komplexen Verkehrszeichen und Erkennung der Baustellen-Spurführungs-Verkehrszeichen Teil 1 und Teil 2 – (Hauptaufwand Fraunhofer IAIS)
- TP3.4: Erkennung von elektronischen Overhead- Baustellen- / sowie Spur-Leiteinrichtungen – (Hauptaufwand Fraunhofer IAIS)
- TP3.5: Erkennung von Begrenzungsobjekten (Baken, Pylonen) für Baustellen (Unterschiedliche Ansätze wurden von Continental und Fraunhofer IAIS umgesetzt)
- TP3.6: Hochgenaue Fahrspurerkennung, basierend auf einem Multi-Kamera-System (Nahfeld), (Hauptaufwand Continental)

Ziele:

Ziel des gesamten Arbeitspaketes 3 war die Erkennung von komplexen Hinweisschildern und die Entwicklung robuster Algorithmen zur Umfelderkennung in Baustellensituationen.

Detailierung TP 3.1: Erkennung von Baustellen-Ankündigungs-Verkehrszeichen inkl. Zusatzzeichen (Continental)

Die Erkennung von Baustellenbereichen, um eine evtl. Fahrerübergabe in solchen Situationen einzuleiten, stellt im Bereich des hochautomatisierten Fahrens eine besondere Herausforderung dar. Hierfür ist eine Erkennung von verschiedenen Baustellenverkehrszeichen und Zusatzzeichen, insbesondere einer Angabe der Distanz zur Baustelle, notwendig und muss verarbeitet werden.

Verfahren wie *Triangle Detection* z.B. [13], *Classification und Optical Character Recognition (OCR)* z.B. [14] sind hierfür naheliegend und mussten bzgl. Performanz auf Nahfeld- und Fernfeldbereich untersucht werden. Die Verwendung alternativer Verfahren zur Detektion insbesondere der Zusatzzeichen war hiervon nicht ausgeschlossen und sollte im 2. Teil des Arbeitspaketes untersucht werden.

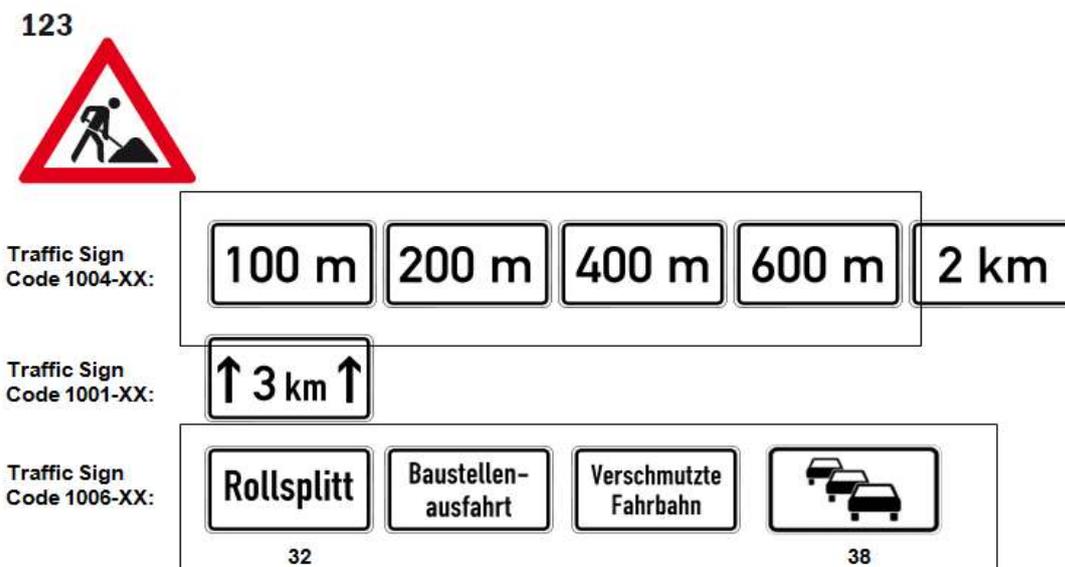


Abbildung 42: Baustellenverkehrszeichen und Zusatzzeichen

Anmerkung TP3.1:

Die Daten für das Training und die Performancebewertung der Algorithmen in Abstimmung mit dem Entwicklungspartner wurden von CMORE bereitgestellt.

Detailierung TP 3.2: Erkennung von auf Anhänger montierten komplexen Hinweisschildern, inkl. der elektronischen Fahrtrichtungsweiser (Continental)

Zum Erkennen des Startpunkts der Baustelle ist die Erkennung der typischerweise auf Anhängern montierten, komplexen Hinweisschildern. Diese sind meist aus unterschiedlichen Einzelschildkomponenten zusammengesetzt und können sich so von Schild zu Schild deutlich unterscheiden. Die Herausforderung hierbei liegt in der Detektion der einzelnen Verkehrszeichenkomponenten, sowie der Interpretation der Gesamtbedeutung des Schildes. Für die Aktuatorik bzw. Plausibilisierung ist gegebenenfalls die Auswertung der elektronischen Fahrtrichtungsweiser relevant. Hierbei gilt es Verfahren zu erproben, die mit unterschiedlich gepulsten, elektronischen Lichtsystemen funktionieren.



Abbildung 43: Komplexe Hinweisschilder

Klassifikations- und musterbasierte Detektionsverfahren sollten dafür entwickelt und erprobt werden. Neben Detektoren für Kreise und Dreiecke werden Teile-basierte Ansätze verwendet, um die Einzeldetektionen zu einer Gesamtdetektion des Hinweisschildes zusammenzufassen. Eine Detektion der Blinklichter kann zur Einschränkung des Suchbereichs (ROI - Region of Interest) verwendet werden.

Nachfolgende Abbildung zeigt Beispiele auf Anhänger montierter komplexer Hinweisschilder.

Anmerkung TP3.2:

Die Daten für das Training und die Performancebewertung der Algorithmen in Abstimmung mit dem Entwicklungspartner wurde von CMORE bereitgestellt.



Abbildung 44: Detektion eines komplexen Hinweisschilds

Detailierung TP 3.3 Detektion von Komplexen Verkehrszeichen und Erkennung der Baustellen-Spurführungs-Verkehrszeichen (Fraunhofer IAIS)

Im Umgebungsbereich der Baustellen werden mit Verfahren zur Erkennung komplexer Verkehrszeichen Hinweisschilder detektiert und dem Fahrer der relevante Bildausschnitt visualisiert. Da die Bandbreite der möglichen Hinweisschilder sehr groß ist und von Spurführungszeichen bis zu Umleitungsempfehlungen reichen kann, werden nur die Spurführungszeichen einer weiteren inhaltlichen Analyse unterzogen.

Die Erkennungspipeline der Spurführungszeichen teilt sich in die Verarbeitungsschritte Detektion Analyse und Tracking auf.

Detektion der Spurführungszeichen

Zur Detektion der Spurführungszeichen wurden drei verschiedene Verfahren entwickelt und untersucht.

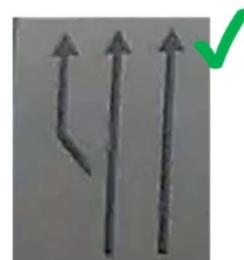


Abbildung 45: Zweistufige Detektion eines Spurführungszeichens

Im ersten Schritt werden rechteckige Formen im Bild lokalisiert (links) und im zweiten Schritt durch ein CNN klassifiziert, wobei nicht relevante Objekte zurückgewiesen werden (rechts).

Boosted Cascades

Es wurde eine eigens implementierte Variante der Boosted Cascades eingesetzt, die auf Basis von Haar-Merkmalen und zuvor gesammelten Positivbeispielen von Spurführungszeichen trainiert wurde. Schon während der frühen Entwicklung wurde ersichtlich, dass dieses Verfahren zwar erfolgversprechende Ergebnisse liefert, jedoch auf den hochauflösenden Aufnahmen des Projekts nicht performant genug arbeitet. Demzufolge wurde dieses Verfahren nicht weiterverfolgt und sich auf die folgenden Verfahren konzentriert.

Rechteckdetektor und Convolutional Neural Network (CNN)

Es wurde ein zweistufiger Ansatz zur Spurführungszeichenerkennung umgesetzt, bei dem im ersten Schritt eine Hypothese von rechteckigen Objektpositionen von einem Rechteckdetektor bestimmt, die im zweiten Schritt durch Klassifikationen eines CNNs überprüft werden. Dazu wird der Bildausschnitt jeder Hypothese (s. Abbildung 45) an ein CNN übergeben und die jeweilige Objektklasse bestimmt, wodurch falsche Hypothesen zurückgewiesen werden. Die zur Entwicklung benötigte Datenbasis wurde wie in Abschnitt Software- und Datengrundlage beschrieben aufgebaut und zum Training des CNNs eingesetzt.

Der Rechteckdetektor ist ein Verfahren, das auf der Radialsymmetrie basiert. In der Kantenrepräsentation des Eingabebildes werden rechteckige Objekte in unterschiedlichen Skalen (Bildpyramide) lokalisiert. Dazu wählt jeder Punkt einer potentiellen Kante eines Rechtecks in einen Akkumulator, in dem sich Hochpunkte für rechteckige Objektzentren ergeben. Der dafür eingesetzte Algorithmus ist durch verschiedene Parameter hinsichtlich

- minimaler und maximaler Rechteckgröße,
- minimale Stärke von wahlberechtigten Kanten,
- Schwellwert für Rechteckhypothesen,
- maximale Rotationsgrad eines Rechtecks,
- Seitenverhältnis eines Rechtecks

einstellbar. Diese Parameter wurden durch qualitative Auswertung von verschiedensten Szenen und hinsichtlich des Use-Cases der Verkehrszeichenerkennung festgelegt. Dabei wurde zwischen Precision und Recall hinsichtlich der Performanz des Rechteckdetektors abgewogen, d.h. eine möglichst hohe Rate an Richtig-Positiven zu möglichst wenig Falsch-Negativen zu erreichen.

Darüber hinaus wurde der Detektor aufbauend auf den Arbeiten von [12] auf den algorithmischen Ebenen

- multiskalen Akkumulator,
- Fix-point Arithmetik,
- Einschränkung Rotationsgrad der betrachteten Gradienten,
- Integralkalkulation der Votinglines

hinsichtlich der Laufzeit optimiert. Durch diese Optimierungen wurde eine effiziente, echtzeitfähige Rechteckdetektion geschaffen, die auch unter geringer Rechenleistung (z. B. bei ARM Mikroprozessoren) und hochauflösenden Bildern (> 640x480 px) performant ist.

Zur Verifikation und Klassifikation der rechteckigen Objekthypothesen wurde eine Standardarchitektur eines CNNs umgesetzt. Diese basiert auf der mittlerweile klassischen LeNet-Architektur [15], bestehend aus alternierenden Faltungs- und Max-Pooling-Schichten, abgeschlossen durch zwei Fully-Connected Schichten (s. Abbildung 46).

Zum Training wurden die bereitgestellten Labeldaten zur Objektklassifikation vorbereitet. Dazu wurden die durch Bounding Box und Klasse versehenen Objekte als Paare aus Bildausschnitt und Klasse verwendet. Es wurden folgende Hyperparameter zum Trainieren der Modelle angewandt:

- Optimierer: Adam [16]
- Lernrate: 0.001
- Loss: Crossentropy
- Trainingsiterationen: 400.000

Zur Regularisierung des Trainingsvorgangs wurde Data Augmentation mit zufälligen Rotationen und zufälligem vertikalen Spiegeln angewandt. Als mittleres Seitenverhältnis wurde 1,30 (0,15 STD) für Spurführungszeichen bestimmt, auf dessen Basis das

Seitenverhältnis konstant für die Eingabegröße des CNNs festgesetzt wurde, um die Verzerrung durch Skalierung zu minimieren.



Abbildung 46: Schematische Darstellung der CNN-Architektur

Es wurde in 8 Objektklassen klassifiziert, die sich aus der im Projekt festgelegten Labelspezifikation ergeben. Dazu wurden 7 Cluster von Spurführungszeichen, z. B. Überleitungs- und Einengungstafel, gewählt und durch eine Negativklasse erweitert. Diese Cluster wurden für die von CMORE durchgeführte Validierung verwendet. Die optional nachgeschaltete Analyse der Spurführungszeichen behandelt die Cluster der Spurführungszeichen gleichermaßen.

Eingabebilder werden auf die einheitliche Bilddimension 3x50x65 (3 Farbkanäle) skaliert. Die hier gezeigte Standard-Architektur berechnet die Bildmerkmale in den alternierten Faltungsschichten (conv2d) mit 16 3x3 Kernen MaxPooling-Schichten mit 2x2 Kernel und Schrittweite 2 (strides 2) und klassifiziert diese in den Fully-Connected-Schichten (fc) mit 128 versteckten Neuronen und 8 Ausgabeneuronen, entsprechend den 8 Klassen.

Parameter	Ergebnis
Eingabegröße	50x65 Pixel
Reduzierungsfaktor der Negativbeispiele	3
Erweiterungsfaktor der Bounding Box	1,5
Minimale Objektgröße	45 Pixel
Batchsize	64

Tabelle 3: Ergebnis der Experimente zur Parametrisierung des CNN-Trainings

Ergebnis der Experimente zur Parametrisierung des CNN-Trainings. Die Eingabegröße legt die Einheitsgröße, auf welche das Eingabebild skaliert wird, fest. Der Reduzierungsfaktor verringert die Anzahl der im Training verwendeten Negativbeispiele. Der Erweiterungsfaktor steuert die Menge am Objekt umliegenden Hintergrund, der im Eingabebild zur Verfügung gestellt wird. Die minimale Objektgröße legt fest, ab welcher Objektgröße ein Objekt zum Training verwendet wird. Die Batchsize steuert die Anzahl an Beispielen pro Gewichtsupdate während des Trainings.

Neuronales Netzwerk – You Only Look Once Version 3 (YOLO-V3)

Auf Basis der Basisarchitektur des YOLO Version 3 [17] wurde ein Neuronales Netz trainiert, das die Detektion der Spurführungszeichen, im Gegensatz zum vorherigen Ansatz, in einem Schritt durchführt. Die Basisarchitektur des Netzwerks wurde angepasst, um den Tradeoff

zwischen Laufzeit und Genauigkeit zu optimieren. Die Basisarchitektur ist für den gegebenen Use-Case deutlich überparametrisiert, da es auf die Detektion von 80 Objekten (z. B. COCO Datensatz) und mehr ausgelegt ist. Empirisch wurde eine deutlich kleinere, geeignete Architektur ermittelt, die schnellere Laufzeiten ermöglicht.

Zum Training des Neuronalen Netzes wurden die bereitgestellten Daten aus dem Projekt verwendet. Dazu wurden in die Kalenderwochen 6, 7 und 8 aus dem Jahr 2018 als Trainingsdaten, die Woche 9 zur Validierung herangezogen. Da die Daten durch einen Active Learning Ansatz gelabelt wurden und fehlerhafte Label enthalten können, wurden Datensäuberungsschritte durchgeführt. Hierbei wurden beispielsweise doppelte Detektionen von ein und demselben Objekt herausgefiltert und offensichtliche Klassifikationsfehler manuell aussortiert. Der daraus resultierende Trainingsdatensatz enthält ca. 50.000 Boxlabel von Spurführungszeichen, der Validierungsdatensatz ca. 6.632 Boxlabel.

Zur Evaluation wurde für jedes detektierte Objekt eine Konfidenz sowie Überlappung der prädiktierten sowie gelabelten Box ermittelt. Objekte mit Konfidenzwerten unter 0.25 wurden herausgefiltert und Boxpaare mit einer Intersection over Union (IoU) unter 0.5 wurden als Falschnegative gewertet. Unter dieser Voraussetzung wurde eine Average Precision (AP) von 54.71% erreicht (3388 richtig Positive und 3244 falsch Positive). Hier ist anzumerken, dass das nachgeschaltete Tracking den Großteil der falsch Positiven wieder herausfiltert. Darüber hinaus wurden Schwellwerte für kleine Objektdetektionen ermittelt, da hier vor allem falsch Positive auftreten.

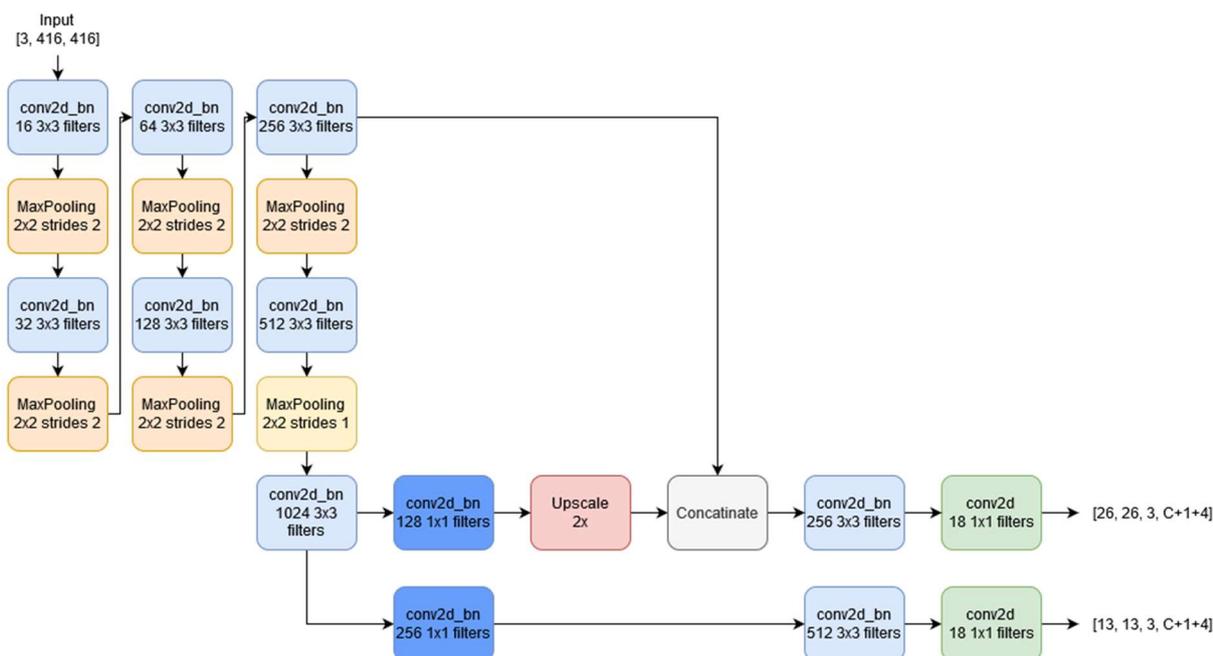


Abbildung 47: Schematische Darstellung der CNN-Architektur zur Detektion der Spurführungszeichen

Die YOLO-V3 Basisarchitektur wurde für eine schnellere Laufzeit angepasst. Dazu wurden weniger Convolutional-Schichten sowie zwei statt drei Ausgänge (Skalen) verwendet

Analyse der Spurführungszeichen

Die Analyse der Spurführungszeichen ist der Detektion nachgeschaltet und arbeitet auf dem durch den Detektionsschritt eingeschränkten Suchbereich im Eingabebild (s. Abbildung 48). Die auf Spurführungszeichen enthaltenen Informationen lassen sich in Pfeilinformation und Zusatzinformation aufgliedern. Beide Informationen werden separat extrahiert und anschließend aggregiert.

Pfeilendendetektion

Zur Extraktion der Pfeilinformationen wurde ein mehrstufiges Verfahren entwickelt, das im ersten Schritt die Pfeilspitzen und -enden detektiert, im zweiten Schritt einen Pfad zwischen diesen Pfeilen findet und abschließend durch anhand quadratischer Approximation einen Pfeil klassifiziert.

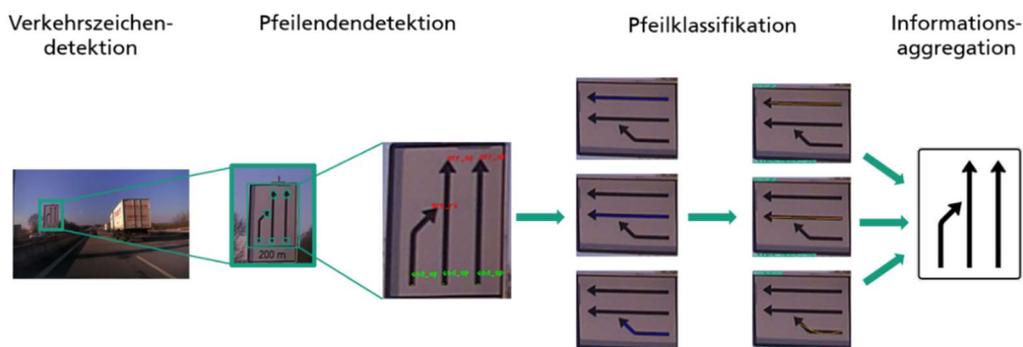


Abbildung 48: Schematische Darstellung der Pipeline zur Erkennung der Spurführungszeichen

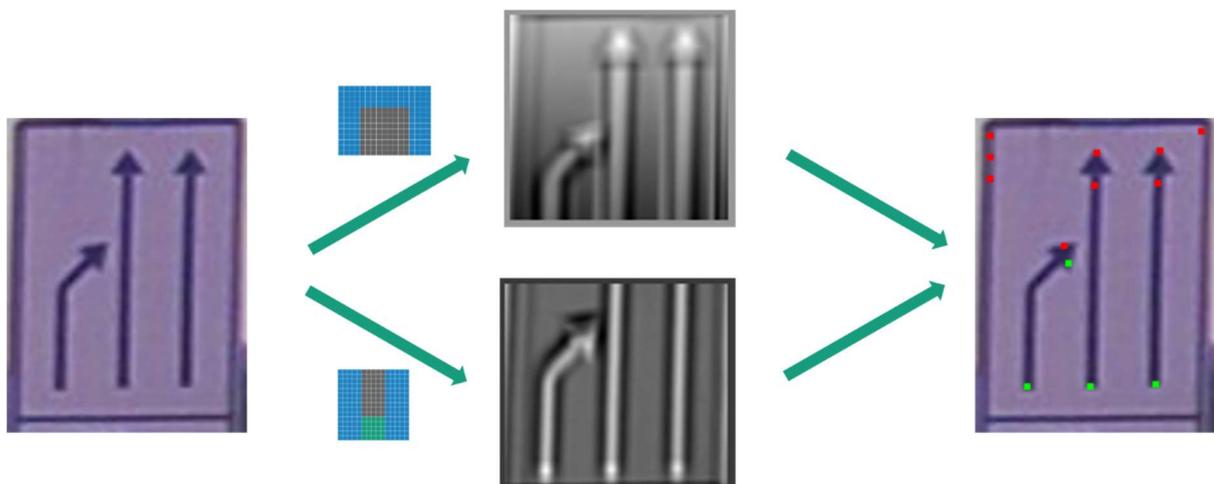


Abbildung 49: Schematische Darstellung der Pfeilendendetektion mittels eigens entwickelten Filters

In der Abbildung kann man sehen wie auf das Eingabebild links zwei Filter für die Spitzen und Enden der Pfeile angewandt werden. Im Hochpunktbild (Mitte) werden Hochpunkte ermittelt. Rechts sind die Hochpunkte im Eingabebild eingefügt (rot: Spitze, grün: Ende)

Zur Detektion der Pfeilspitzen und –enden wurden zwei Verfahren umgesetzt. Das erste Verfahren basiert auf klassischer Bildverarbeitung: Es wurden zwei Filter manuell entworfen, die speziell für die Detektion von Pfeilenden geeignet sind. Die Größe und Form der Filter wurden auf die Größe und Form von Pfeilspitzen und –enden nach einer Normierung des Eingabebildes festgesetzt.

Die qualitative Auswertung ergab, dass zu hohe Filterantworten in den Rändern der Schilder generiert wurden. Dementsprechend wurde ein alternatives Verfahren entwickelt.

Das zweite Verfahren basiert auf einem Deep Learning Ansatz: Ebenso wie für die Detektion der gesamten Spurführungszeichen, wurde ein Neuronales Netz zur Objektdetektion auf Basis von YOLO-V3 implementiert und trainiert. Zum Training des Netzes wurde auf einer Teilmenge des Trainingsdatensatz der Spurführungszeichen ein neuer Datensatz aufgebaut, der die Bildausschnitte der Spurführungszeichen mit Bounding Box Laben der Pfeilspitzen und –enden enthält.

Der aufgebaute Datensatz bestand aus 82 Beispielen, dessen Anzahl durch Data Augmentation um den Faktor 4 erweitert wurde. In Abbildung 50 ist die eingesetzte Data Augmentation beispielhaft dargestellt.

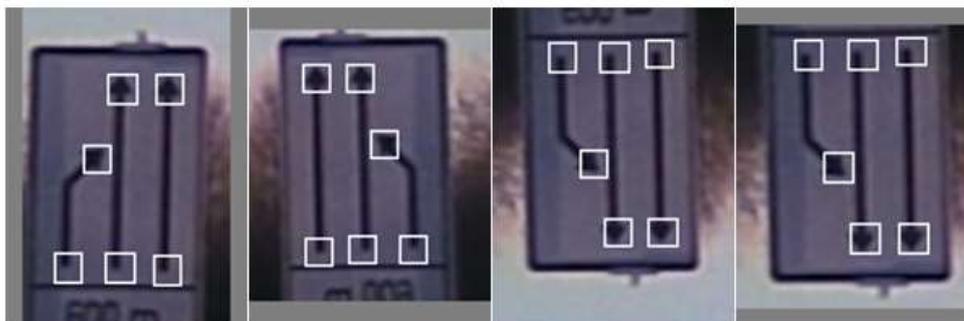


Abbildung 50: Beispielhafte Darstellung der Dataaugmentation der Pfeildetektion

Zur Erweiterung des Datensatzes zur Pfeildetektion, wurde mittels Translation, Skalierung und Spiegeln von Beispielen der Datensatz erweitert. Aus einem Eingabebild wurden vier Varianten mit zufällig ausgewählten Transformationen erzeugt.

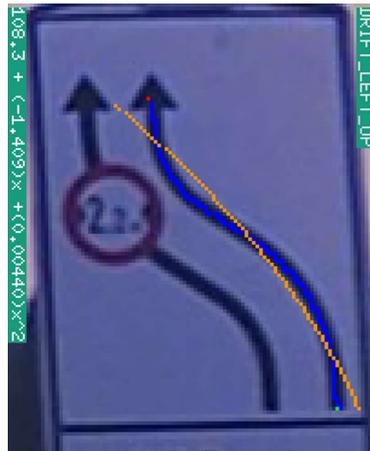


Abbildung 51: Darstellung der Pfeilklassifikation

In blau ist der gefundene Pfad vom roten Start- zum grünen Endpunkt, in orange die approximierten, quadratischen Funktion angezeigt.

Pfeilklassifikation

Nach der Detektion der Pfeilspitzen wird mittels eines angepassten Dijkstra-Algorithmus ein Pfad zwischen den Start- und Endpositionen bestimmt. Dieser Pfad wird durch eine quadratische Funktion approximiert. Anhand der Funktionsparameter wird die Klassifikation der Pfeile durchgeführt (s. Abbildung 51).

Zusatzinformationen

Die Erkennung von Zusatzinformationen, der maximalen Spurbreiten und Entfernungsangaben wurden mit Kreisdetektor und histogrammbasierter Detektion umgesetzt. Das Auslesen der Informationen wurde mittels OCR untersucht.

Bei den Spurbreiten wurde die erforderliche, experimentell ermittelte Mindesthöhe für robuste Ergebnisse bei gegebenen Kameraeigenschaften von 16 Pixeln nicht erreicht werden. Die qualitative Auswertung bestätigte diese zuvor ermittelte Mindesthöhe.

Auch die Entfernungsangaben wurden qualitativ betrachtet und an Einzelbeispielen untersucht. Für die Detektion

Als OCR wurde Tesseract 3 sowie das von Fraunhofer IAIS entwickelte DeePER [10] eingesetzt.

Informationsaggregation

Über die Positionen der einzelnen Objekte auf Pixelebene wurden die Informationen miteinander verknüpft und über entsprechende Logikverknüpfungen miteinander kombiniert. Die Pfeile wurden von links nach rechts im Bild angeordnet und visualisiert.

Tracking

Zum Tracking wurde ein adaptierter Kalman-Filter umgesetzt. Bei naheliegender, bestehendem Track wird ein Spurführungszeichen, diesem hinzugefügt, andernfalls wird ein

neuer Track erzeugt. Die zum Ende eines Tracks enthaltene Informationsaggregation wurde anhand der maximal existierenden, validen Pfeile umgesetzt.

Durch das Tracking wird die zeitliche Komponente von Videoaufnahmen ausgenutzt, um die Robustheit der Spurführungszeichenerkennung zu erhöhen. Eine Mindestlänge eines Tracks gewährleistet, dass ein Objekt über mehrere Bilder detektiert wurde und minimiert die Möglichkeit von Falsch-Positiv-Detektionen.

Detailierung TP3.4: Erkennung von elektronischen Overhead- Baustellen- / sowie Spur-Leiteinrichtungen (Fraunhofer IAIS)

Die Erkennung von Overhead-Verkehrszeichen ist in die Verarbeitungsschritte und entsprechenden Unterkapitel Detektion, Klassifikation und Tracking aufgeteilt.

Die Klassifikation arbeitet auf den Hypothesen der Detektion, das Tracking auf den validen Klassifikationen. Die Overhead-Verkehrszeichen, lassen sich anders als die Spurführungszeichen direkt in eine Klasse einordnen und bedürfen demzufolge keinem komplexen Analyseschritt (Vergleiche AP 3.3).

Im Folgenden wird sich ausschließlich auf runde und dreieckige Overhead-Verkehrszeichen beschränkt, da eine nicht ausreichende Datensammlung von LED-Pfeilen möglich war. Demzufolge wurde keine weitere Untersuchung von LED-Pfeile durchgeführt.

Detektion der Overhead-Verkehrszeichen

Zur Detektion von runden und dreieckigen Overhead-Verkehrszeichen werden ein Kreis- sowie Dreiecksdetektor eingesetzt. Die Detektoren basieren auf den Vorarbeiten [11], die genauso wie der Rechteckdetektor auf dem Ansatz der Radialsymmetrie aufbauen.

In der Kantenrepräsentation des Eingabebildes werden die runden bzw. dreieckigen Objekte in unterschiedlichen Skalen (Bildpyramide) lokalisiert. Beim Dreieckdetektor wird anders als beim Kreisdetektor nach den drei Kanten unterschieden und eine Erhöhung im Akkumulator wird nur dann durchgeführt, wenn ein Kantenpixel die entsprechende Ausrichtung einer Kante mit einer Toleranz von +/- 10 Grad einhält.

Die dafür eingesetzten Algorithmen sind beide durch verschiedene Parameter hinsichtlich

- minimaler und maximaler Objektgröße,
- minimale Stärke von wahlberechtigten Kanten,
- Schwellwert für Objekthypothesen

parametrisierbar. Diese Parameter wurden durch qualitative Auswertung von verschiedensten Szenen und hinsichtlich des Use-Cases der Verkehrszeichenerkennung festgelegt. Dabei wurde zwischen Precision und Recall hinsichtlich der Performanz der Detektoren abgewogen, d.h. eine möglichst hohe Rate an Richtig-Positiven zu möglichst wenig Falsch-Negativen zu erreichen.

Ein Kantenpixel der Formen Kreis (a), Dreieck (b) und Rechteck (c), werten in halber Objektgröße in einen Akkumulator. In diesem Akkumulator entsprechen die Hochpunkte den Detektionen der Objekte. Abbildung entnommen aus [12].

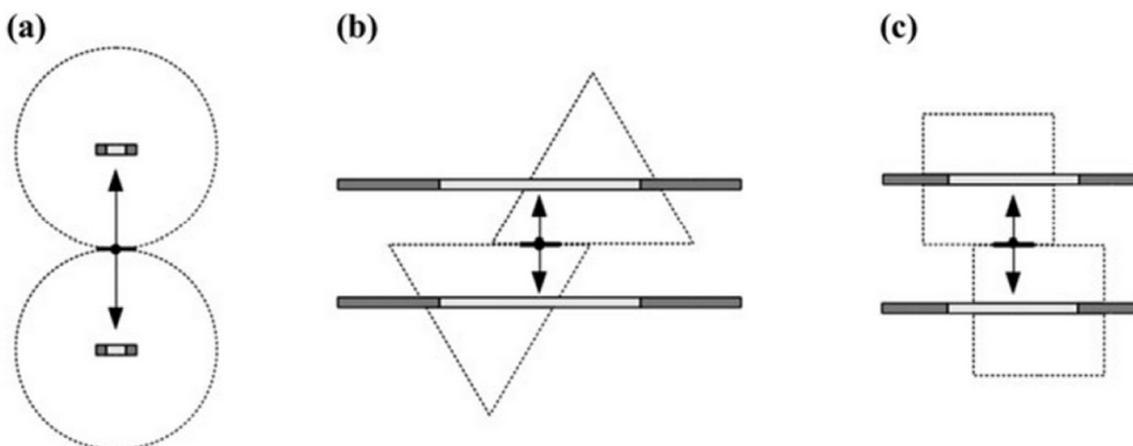


Abbildung 52: Schematische Darstellung des Voting-Prozesses von Kantenpixeln der Formdetektoren

Klassifikation der Overhead-Verkehrszeichen

Zur Klassifikation wurde eine Standardarchitektur (Abbildung 46) eines CNNs eingesetzt. Es wurde in die drei dreieckigen LED-Varianten der baustellenrelevanten Klassen „Stau“, „Gefahrenstelle“ und „Baustelle“ unterschieden. Darüber hinaus wurden Maximalgeschwindigkeiten der runden LED-Varianten klassifiziert.

Als Vorverarbeitungsschritt wurden die Objekthypothesen des vorangeschalteten Detektionsschritts einer Farbraumtransformation von RGB in YCbCr überführt und der Y-Kanal kontrastnormalisiert.

Das CNN wurde mittels Dataaugmentation trainiert, wobei zufällige Rotationen, Translationen und Skalierungen auf ein Beispiel angewendet wurden.

Parameter	Wert
Eingabegröße	32x32 Pixel
Reduzierungsfaktor der Negativbeispiele	3
Erweiterungsfaktor der Bounding Box	1
Minimale Objektgröße	20 Pixel
Batchsize	64
Data Augmentation	Rotation, Translation, Skalierung
Vorverarbeitung	YCbCr-Transformation, Kontrastnormalisierung

Tabelle 4: Übersicht der Parameter zum Training des CNNs zur Klassifikation der Overhead-Verkehrszeichen



Abbildung 53: Erkennungsergebnis der Overhead-Verkehrszeichen

In der Abbildung kann man sehen, dass trotz der Pulsung des rechten Overhead-Verkehrszeichens „SPEED_LIMIT_80_LED“ wird das Tracking aufrechterhalten bis das Objekt wieder im Bild sichtbar wird.

Auf den intern aufgebauten Datensätzen wurden Genauigkeiten von über 96% erreicht.

Tracking

Durch die Pulsung der LED-Anzeigen können die Verkehrsinformationen für einige Einzelbilder der Kamera nicht sichtbar sein. Anhand qualitativer Untersuchung wurde festgestellt, dass dies mittels des eingesetzten Trackings kompensierbar ist (Abbildung 53).

Es wurde wie bereits beschrieben, ein adaptierter Kalman-Filter eingesetzt.

Detailierung TP3.5: Erkennung von Begrenzungsobjekten (Baken, Pylonen) für Baustellen (Fraunhofer IAIS)

Die Erkennung der Baken ist in die drei Verarbeitungsschritte entsprechend der folgenden Unterkapitel Detektion, Klassifikation und Tracking aufgeteilt.

Wie in AP 3.4 arbeitet die Klassifikation auf den Hypothesen der Detektion, das Tracking auf den validen Klassifikationen.



Abbildung 54: Erkennungsergebnis der Bakenerkennung

Parameter	Wert
Eingabegröße	16x64 Pixel
Reduzierungsfaktor der Negativbeispiele	3
Erweiterungsfaktor der Bounding Box	1
Minimale Objektgröße	20 Pixel
Batchsize	64
Data Augmentation	Rotation, Translation, Skalierung
Vorverarbeitung	YCbCr-Transformation, Kontrastnormalisierung

Tabelle 5: Übersicht der Parameter zum Training des CNNs zur Klassifikation der Baken

Detektion

Zur Detektion der Baken wurde ein Bakendetektor entwickelt, der ebenfalls auf der Radialsymmetrie basiert. Dazu wurde das rot-weiß Muster der Baken und deren relative Position zueinander definiert und die Kantenpixeln der Baken voten entsprechend in Akkumulatoren. Das widerkehrende Muster der Baken wird genutzt, indem mehrere Akkumulatoren kombiniert werden und sich so eindeutige Hochpunkte zur robusten Lokalisation der Baken ergeben.

Als limitierende Faktoren der Bakendetektion wurden starke Verdrehungen aus der Bildebene sowie Verschmutzungen der Baken festgestellt.

Auch der Bakendetektor ist durch

- minimale und maximale Objektgröße,
- minimale Stärke von wahlberechtigten Kanten,
- Schwellwert für Objekthypothesen

parametrisierbar.

Diese Parameter wurden durch qualitative Auswertung von verschiedensten Szenen und hinsichtlich des Use-Cases der Verkehrszeichenerkennung festgelegt. Dabei wurde zwischen Precision und Recall hinsichtlich der Performanz der Detektoren abgewogen, d.h. eine möglichst hohe Rate an Richtig-Positiven zu möglichst wenig Falsch-Negativen zu erreichen.

Klassifikation

Für die Klassifikation der Baken wurde ebenfalls eine Standardarchitektur (Abbildung 46) umgesetzt. Diese wurde auf fünf Klassen der Baken trainiert, in der Abbildung sind zwei Varianten der Bakenklassen, die die linke bzw. rechte Fahrspur indizieren.

Als Vorverarbeitungsschritt wurden die Objekthypothesen des vorangeschalteten Detektionsschritts einer Farbraumtransformation von RGB in YCbCr überführt und der Y-Kanal kontrastnormalisiert.

Das CNN wurde mittels Dataaugmentation trainiert, wobei zufällige Rotationen, Translationen und Skalierungen auf ein Bakensample angewendet wurden.

Auf den intern aufgebauten Datensätzen wurden Genauigkeiten von über 96% erreicht.

Tracking

Zum Tracking wurde wie bereits beschrieben, ein adaptierter Kalman-Filter eingesetzt.

Detailierung TP 3.5: Erkennung von Begrenzungsobjekten (Baken, Pylonen) für Baustellen (Continental)

Zur Unterstützung der korrekten Spurführung im Baustellenbereich mussten ebenfalls die mobilen Spurführungselemente wie Baken und Pylonen in einem möglichst breiten Variationsspektrum detektiert werden. Eine Herausforderung bei der Detektion waren Verdeckungen von Baken durch andere Baken, da Baken in kritischen Baustellenabschnitten zum Teil sehr dicht aufgestellt werden. Baken und Pylonen zeichnen sich durch deutliche rot-weiß Steifen aus:



Abbildung 55: Baken und Pylonen

Die für diese Zielsetzung zu untersuchenden Verfahren waren *Pixellabeling* mit *Convolutional Neural Networks* (CNN, Deep Learning) [18] [19]³, *Boosted Cascades* [20]⁴, *Color Segmenting* [21]⁵ und *Color Edges* [22]⁶.

In diesem Teilarbeitspaket wurden folgende Schritte von Continental bearbeitet:

- Auswahl von zwei zu untersuchenden Verfahren in Zusammenarbeit mit IAIS
- Erstellung eines *Proof-of-Concept* für ein gewähltes Verfahren
- Evaluierung der beiden Verfahren
- Optimierung des gewählten Verfahrens in Zusammenarbeit mit IAIS
- Anforderungsanalyse für die zweite Entwicklungsphase
- Optimierung des Verfahrens

³ Auf den Seiten von CityScapes und Kitti Dataset findet man eine Übersicht über aktuelle Algorithmen plus Benchmarks

⁴ Hinweis für den Einstieg in das Thema Boosted Cascades

⁵ Hinweis für den Einstieg in das Thema Color Segmenting

⁶ Hinweis für den Einstieg in den Bereich Color Edges



Abbildung 56: Detektionen von Baken auf Autobahn (grün)

Anmerkung TP3.5:

Die Daten für das Training und die Performancebewertung der Algorithmen in Abstimmung mit dem Entwicklungspartner wurden von CMORE bereitgestellt.

Vom Fraunhofer IAIS wurden gemäß Planung folgende Teilarbeitsschritte bearbeitet:

- Auswahl von zwei zu untersuchenden Verfahren in Zusammenarbeit mit Continental
- Erstellung eines *Proof-of-Concept* für ein gewähltes Verfahren
- Evaluierung der beiden Verfahren
- Optimierung des gewählten Verfahrens in Zusammenarbeit mit Continental
- Anforderungsanalyse für die zweite Entwicklungsphase
- Optimierung des Verfahrens
- Entwicklung und Evaluierung eines CNN-basierten *Pixel-Labeling* Ansatzes für überlappende Baken

TP übergreifende Arbeiten: Objektdetektion mittels neuronaler Netzwerke / Deep Learning

Im Laufe des Projekts wurde evaluiert, welche Erkennungsalgorithmen sich für welches Problem am besten eignen, auch im Hinblick auf die Ressourcensituation in einem Fahrzeug. Unter Beachtung dieser Rahmenbedingungen wurden verschiedene Benchmarks für Objekterkennungsmethoden zu Rate gezogen, wie z.B. Kitti [18], CityScapes [19] usw. und eine Liste von erfolgsversprechenden Algorithmen erstellt. Diese wurden dann an Hand verschiedener Kriterien (Laufzeit, Rechenaufwand, Erkennungsrate, Optimierungspotenzial, usw.) bewertet. Am Ende wurden dann zwei Algorithmen ausgewählt, die näher betrachtet werden sollten: *Yolo-V3* [23], *SSD-MobileNet* [24] und *RetinaNet* [25].

Hierfür mussten dann folgende Arbeiten zur Objektdetektion übergreifend durchgeführt werden:

- Erstellung eines Datensatzes/Datensätzen zum Training von Baustellenverkehrszeichen, Zusatzzeichen, Baken, Pylonen und komplexen Hinweisschildern
- Aufsetzen einer Architektur zur Detektion von Baken, Pylonen und Baustellenankündigungszeichen (Schildnummer: 123)

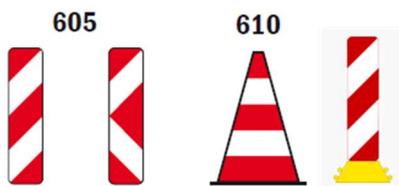


Abbildung 57: Baken und Pylonen



Abbildung 58: Baustellenankündigungszeichen

- Erarbeitung eines Konzepts zur Detektion von mobilen Verkehrszeichen vom Typ 615, 616:



Abbildung 59: mobiles Verkehrszeichen

Parallel konnte damit begonnen werden folgende Arbeiten zur Objektdetektion mittels *Yolo-V3*, *SSD-MobileNet* und *RetinaNet* durch zu führen:

Yolo-V3:

- Anpassungen eines *Yolo-V3* an das gegebene Problem
- Training der echtzeitfähigen *Yolo-V3*
- Integration der echtzeitfähigen *Yolo-V3* Architektur als Tensorflow Applikation in das Fahrzeugframework
- Implementierung einer angepassten Visualisierung

Ergebnisse der Erkennung für Schilder, Baken und Pylone:

Without Tracking											
Milestone3	danger_triangle	dir_down_left	dir_down_right	suppl_explanation_text_baustellen_text_ausfahrt	suppl_explanation_text_regexp_100m	suppl_explanation_text_regexp_200m	drb_pylon	drb_beacon	drb_616		FP
triangle	2547	24	0	0	0	0	0	0	0	0	230
danger_road_works_right	81	304	0	0	0	0	0	0	0	0	60
dir_down_left	0	2	20	3	0	3	0	0	0	0	14
dir_down_right	9	6	0	701	0	0	0	0	0	0	34
suppl_explanation_text_baustellen_text_ausfahrt	9	0	0	0	0	1	0	0	0	0	57
suppl_explanation_text_regexp_100m	1	0	0	0	0	1	0	0	0	0	8
suppl_explanation_text_regexp_200m	0	1	0	0	0	0	0	0	0	0	15
drb_pylon	0	0	0	0	0	0	0	3071	7	0	94
drb_beacon	5	0	0	0	0	0	0	12	2982	0	473
drb_616	0	0	0	0	0	0	0	0	0	0	0
TP	2547	304	20	701	0	1	0	3071	2982	0	
FN	1282	27	12	162	15	32	0	2944	722	0	

Abbildung 60: *Yolo-V3* Ergebnisse

SSD-MobileNet:

- Anpassungen eines SSD –MobileNet an das gegebene Problem
- Training der echtzeitfähigen SSD –MobileNet [26] [24] [27]
- Integration der echtzeitfähigen SSD –MobilNet Architektur als Tensorflow Applikation in das Fahrzeugframework
- Implementierung einer angepassten Visualisierung

Ergebnisse zur Erkennung mittels SSD –MobilNet:

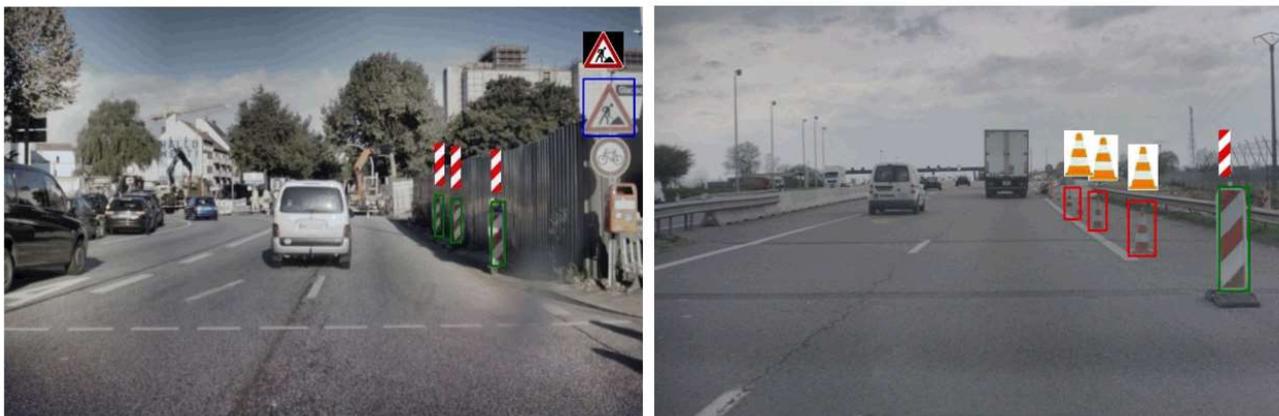


Abbildung 61: Detektierte Baken, Pylonen und ein Baustellenschild mit dem SSD-MobilNet Detektor, dargestellt mit der implementierten Visualisierung

Prediction														
Milestone3	Danger without Road works	danger road works	Dir sign	dir left	dir right	Supple Sign	baustellen ausfahrt	100 m	200 m	pylon	beacon	616		False Positives
Danger without Road works	2638	12	0	0	6	4	0	2	0	0	1	0		16
danger road works	96	302	0	0	0	0	0	0	0	0	0	1		26
Dir sign	0	0	0	0	7	0	0	0	0	0	0	0		1
dir left	5	2	0	21	0	0	0	0	0	0	0	1		17
dir right	9	4	0	0	717	1	0	1	0	0	0	0		50
Supple Sign	2	0	0	0	0	4	1	2	0	0	0	0		10
baustellen ausfahrt	9	0	0	0	0	5	20	12	0	0	0	0		96
100 m	0	1	0	0	0	28	0	41	0	0	0	0		14
200 m	1	0	0	0	0	3	0	6	0	0	0	0		30
pylon	0	0	0	0	0	0	0	0	0	3100	4	0		96
beacon	0	0	0	0	0	0	0	0	0	12	3084	0		425
616	0	0	0	0	0	0	0	0	0	0	0	16		32
TP	2638	302	0	21	717	4	20	41	0	3100	3084	16		
FN	474	23	0	15	185	0	0	65	0	3027	813	8		

Abbildung 62: SSD-MobilNet Ergebnisse

class	mIoU	class	mIoU
ego_vehicle	0,95	chevron	0,52
other/environment	0,93	curb	0,33
road	0,91	stop_line	0,27
crosswalk	0,66	arrow	0,24
road_signs_other	0,58		

Abbildung 63: Verkehrszeichen Extraktion MobileNet

RetinaNet:

- Anpassungen eines *RetinaNets* [25] an das gegebene Problem
- Training eines echtzeitfähigen *RetinaNets*
- Integration der echtzeitfähigen RetinaNet Architektur als Tensorflow Applikation in das Fahrzeugframework
- Implementierung einer angepassten Visualisierung

Für das RetinaNet wurde zum Training ein neues Dataset erstellt aus den gelabelten Daten:

Class Name	Nr
Pylon 	1
Beacon 	2
<u>Danger Road Works Right</u> 	3
<u>Danger sign others</u>	7
Suppl_Explanation_TexRegExp_200m	20
Suppl_Explanation_TexRegExp_400m	22
Suppl_Explanation_TexRegExp_2km	25
<u>Dir Down Left</u> 	17
<u>Dir Down Right</u> 	18
Combined_sign_615 	34
Combined_sign_616 	35

Abbildung 64: Dataset RetinaNet

Die Datenverteilung in dem Dataset sah wie folgt aus:

Experiment 16 Sept exp_21ee2f60 Class Name	Nr	Number of samples total
Pylon 	1	4467
Beacon 	2	53000
<u>Danger Road Works Right</u> 	3	4583
<u>Danger sign others</u> 	7	5939
Suppl_Explanation_200m	20	2210
Suppl_Explanation_400m	22	1178
Suppl_Explanation_600m	37	496
Suppl_Explanation_800m	38	1638
Suppl_Explanation_2km	25	1310
<u>Dir Down Left</u> 	17	802
<u>Dir Down Right</u> 	18	354
Combined_sign_616 and 615 	35	1200
<u>Suppl Explanation Tex XXkm</u>	11	200-500
<u>Suppl Explanation Tex XXm</u>	12	200-500
<u>Suppl Explanation XXm Pic ArrowUp</u>	9	200-500
<u>Suppl Explanation XXKm Pic ArrowUp</u>	10	200-500
<u>Suppl Others</u>	8	8800

Abbildung 65: Datenverteilung RetinaNet

Die Ergebnisse des *RetinaNets* nach dem Training sehen wie folgt aus:

Experiment 16 October exp_0a77a6c	Nr	Number of samples total	VAL % Size	AP (IoU 0.5:0.95) small	AP (IoU 0.5:0.95) medium	AP (IoU 0.5:0.95) large	AR (IoU 0.5:0.95) small	AR (IoU 0.5:0.95) medium	AR (IoU 0.5:0.95) large
Class Name									
Pylon	1	4467	4%	0.178	0.190	-	0.223	0.216	-
Beacon	2	53000	8%	0.759	0.791	0.749	0.794	0.834	0.799
<u>Danger_Road_Works_Right</u>	3	4583	12%	0.630	0.751	0.861	0.668	0.805	0.890
<u>Danger_sign_others</u>	7	5939	12%	0.642	0.764	0.789	0.738	0.827	0.834
Suppl_Explanation_200m	20	2210	10%	0.429	0.616	0.662	0.460	0.676	0.66
Suppl_Explanation_400m	22	1178	13%	0.714	0.716	0.23	0.802	0.759	0.229
Suppl_Explanation_800m	38	1638	10%	0.532	0.540	-0.62	0.750	0.750	-
Suppl_Explanation_2km	25	1310	16%	0.686	0.800	-	0.715	0.841	-
<u>Supp_baust_aus</u>	13			0.211	0.523	-	0.333	0.620	-
<u>Dir_Down_Left</u>	17	802	27%	0.623	0.762	0.816	0.667	0.810	0.843
<u>Dir_Down_Right</u>	18	354	0%	-	-	-	-	-	-
Combined_sign_616 and 615	35	1200	--	0.600	0.656	0.810	0.625	0.712	0.857
<u>Suppl_Explanation_XXm_Pic_ArrowUp</u>	9	200-500	0%	-	-	-	-	-	-
<u>Suppl_Explanation_XXKm_Pic_ArrowUp</u>	10	200-500		0.580	0.650	-	0.647	0.685	-
<u>Suppl_Others</u>	8	8800	7%	0.554	0.612	-	0.638	0.705	-

Area ranges : small[650-32*32] medium[32*32- 96*96] large[96*96 – any]

Abbildung 66: Ergebnisse RetinaNet

Generell hat sich gezeigt, dass die Erkennung mit dem *RetinaNet* die beste Performance über alle Klassen in Kombination mit nachgeschaltetem Tracking-Verfahren zeigt, jedoch gibt es auch hier noch Verbesserungspotenzial, da die Datenmenge im Vergleich zu einem Serienprojekt doch relativ klein war und die Datenverteilung noch optimiert werden kann. Einer der entscheidenden Vorteile des *RetinaNets* ist, dass es alle gewünschten Objekte gleichzeitig erkennen kann und so das ganze System in einem Neuronalem Netz vereint ist.

Detailierung TP 3.6: Hochgenaue Fahrspurerkennung, basierend auf Multikamera System Ansatz (Continental)

Für die Umsetzung der Spurerkennung, basierend auf vier Nahfeldkameras mit einem vereinten Sichtbereich von 360°, sollte unter anderem die Erweiterbarkeit des Kalman Filters für das Tracking der Fahrbahnmarkierungen untersucht werden.

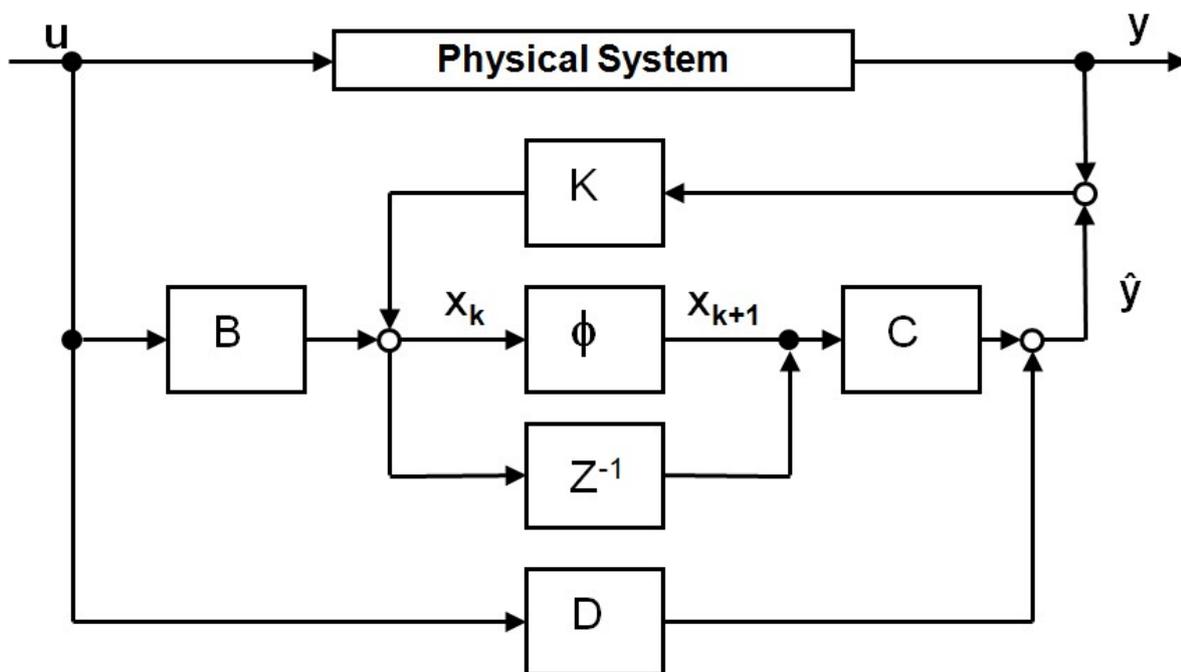


Abbildung 67: Physical System

Für das Multiple-Objects-Tracking der detektierten Spursegmente sollten die bereits vorhandenen Ansätze basierend auf einer Mono-Kamera auf das Vier-Kamera-System übertragen, und dessen Leistungsfähigkeit ermittelt werden. Der Einsatz von davon abweichenden Methoden des Trackings mittels Multi-Kamera-Systemen war hiervon nicht ausgeschlossen.

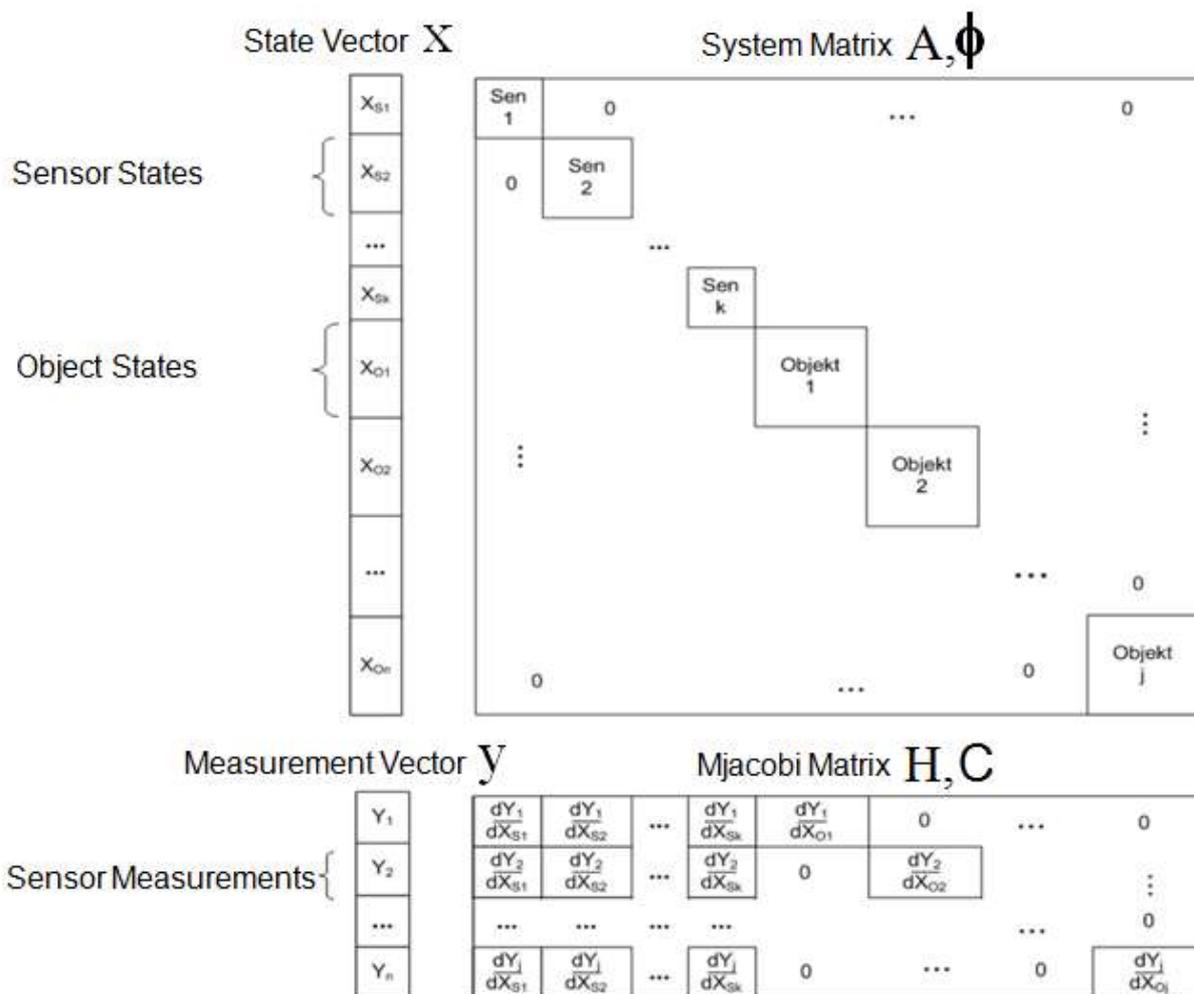


Abbildung 68: Systemmatrix

Das Ziel der modellbasierten Fusionierung war eine 360° Detektion und Tracking von Spurmarkierungen. Mit einer hohen Auflösung im Nahbereich wurde das Ziel verfolgt, eine genaue Spurdetektion- und Spurführung in engen Baustellenszenarien zu ermöglichen. Die Performance wurde im Vergleich zu aktuell am Markt etablierten Front- / Fernbereichskameras erhöht.

Mithilfe der unterschiedlichen Perspektiven der Randbebauungsobjekte von mindestens zwei Kameras und unter Zuhilfenahme eines Fusionskonzeptes, sollte im Rahmen dieses Projektes ebenfalls die Detektion von erhabenen Strukturen erforscht werden (Leitplanken, Betonbarrieren).

Semantische Segmentierung & Frameworkaufbau für Detektionen basierend auf neuronalen Netzwerken / Deep Learning

Im Bereichszeitraum wurde zur Weiterentwicklung des „Redvine Frameworks“ beigetragen, sowie konzeptionelle Arbeit im Rahmen der Datengenerierung (Design und Spezifikation der Label Spezifikation) geleistet. Auf Basis der generierten Daten, hier pixelweise gelabelte Bilder, wurde außerdem ein prototypisches *Fully Convolutional Network* (FCN) zur semantischen Segmentierung generiert.

Im Laufe des Projekts wurde die Performance der semantischen Segmentierung kontinuierlich gesteigert. Diese Verbesserungen leiten sich von zusätzlichen Trainingsdaten aus der Zieldomäne (Surroundview-Kamera) und Architekturänderungen des Netzes ab. Abbildung 28 zeigt die semantische Segmentierung des Basisnetzes, welches auf Frontkamera-Daten trainiert wurde (erste Zeile) und des auf die Surroundview-Domäne adaptierten Netzes.

Juni 2016 :



November 2017 :

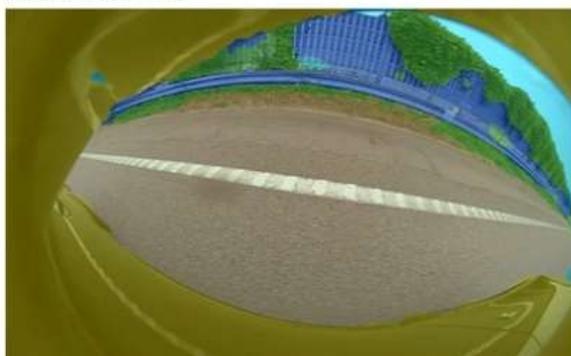


Abbildung 69: Evolution Fahrbahnerkennung

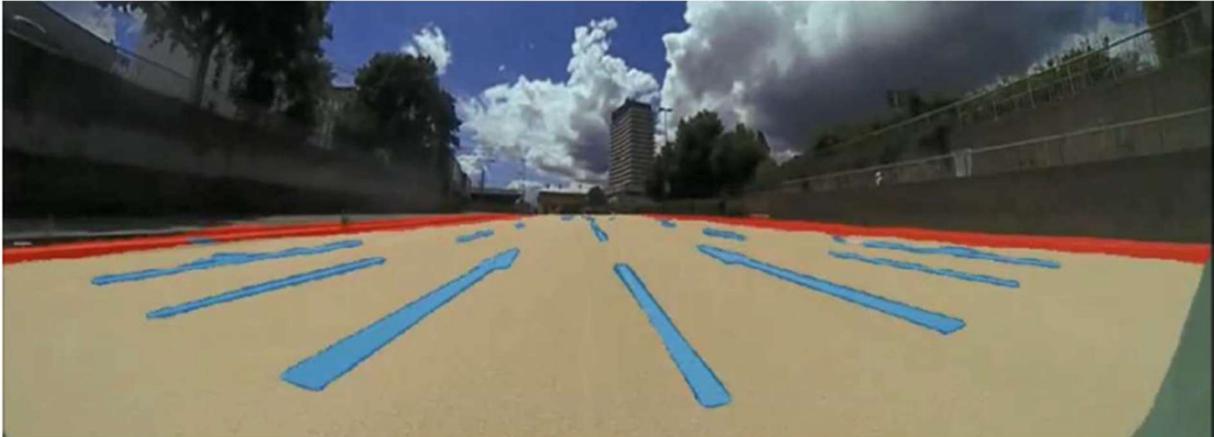


Abbildung 70: Beispiel semantische Segmentierung zur Spurerkennung, Juni 2019

Hauptsächlicher Nutzen dieser Detektionsmethode für das Projekt AutoConstruct besteht in der hochgenauen Extraktion des befahrbaren Bereiches, sowie der Erkennung der Randbebauung.

Ergebnisse der Erkennung der Semantischen Segmentierung auf Pixelbasis:

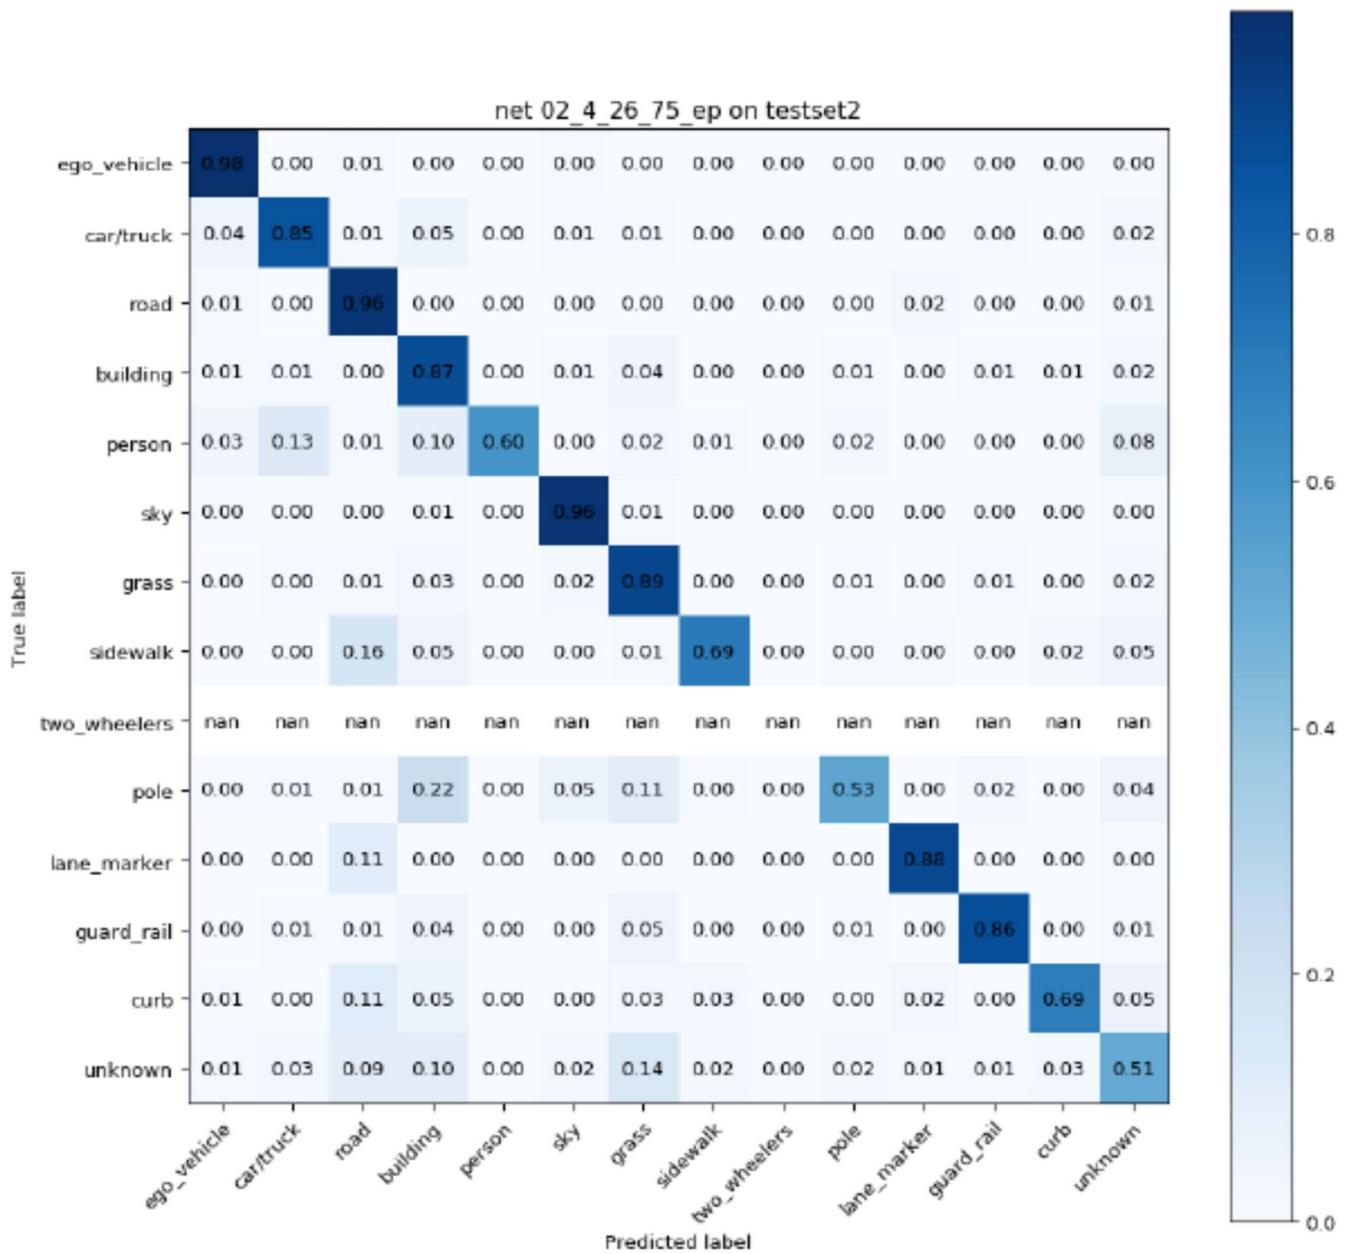


Abbildung 71: Confusion Matrix der vollständigen semantischen Segmentierung, Juni 2019

class	mIoU
ego_vehicle	94,975%
sky	93,597%
road	92,690%
grass	79,059%
building	75,624%
car/truck	73,544%
guard_rail	70,876%
lane_marker	69,182%
sidewalk	57,597%
curb	52,087%
person	49,217%
unknown	37,457%
pole	28,238%

Abbildung 72: Mean IoU Werte der vollständigen semantischen Segmentierung, Juni 2019

Farberkennung Weiße / Gelbe Spurmarkierungen

Ein Verfahren zur farblichen Trennung von weißen/gelben Fahrbahnmarkierungen anhand der komprimierten und Ton-gemappten Surround View Kamera Bildern wurde entwickelt.

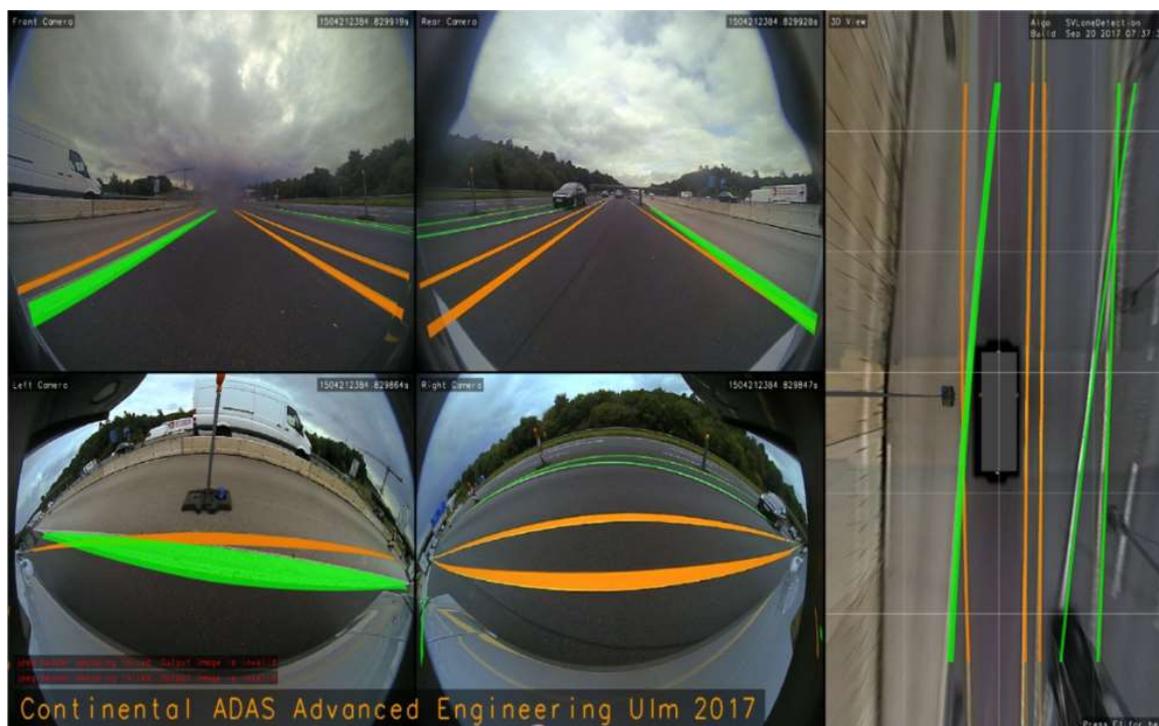


Abbildung 73: Fahrbahnmarkierungserkennung Gelb und Weiß

Das Verfahren wurde in das bestehende System zur Spurdetektion integriert.

Das Verfahren wurde anhand von aufgezeichneten Messungen, sowie im Fahrzeug getestet und evaluiert. Die Testergebnisse haben die Wirksamkeit der eingesetzten Verfahren bestätigt, eine quantitative Auswertung war nicht möglich, da Ground Truth Daten fehlen.

Auf Grund Thruth Daten wurde an der Stelle verzichtet, da es zu dem Aufnahmezeitpunkt kein geeignetes Vergleichssystem gab

Anmerkung TP3.6:

Die Daten für das Training und die Performancebewertung der Algorithmen in Abstimmung mit dem Entwicklungspartner wurden von CMORE bereitgestellt.

Ergebnisse im Rahmen des Arbeitspaketes 3 von Continental:

TP 3.1:

- Problembeschreibung
- Konzeptdefinition
- Es wurden klassische Ansätze, wie auch neuartige Objekterkennungsalgorithmen evaluiert und gegeneinander bewertet
- Algorithmen wurden implementiert
- Ergebnisse wurden ausgewertet und verglichen

TP 3.2

- Problembeschreibung
- Konzeptdefinition
- Es wurden klassische Ansätze, wie auch neuartige Objekterkennungsalgorithmen evaluiert und gegeneinander bewertet
- Algorithmen wurden implementiert
- Ergebnisse wurden ausgewertet und verglichen

TP 3.5

- Problembeschreibung
- Konzeptdefinition
- Es wurden klassische Ansätze, wie auch neuartige Objekterkennungsalgorithmen evaluiert und gegeneinander bewertet
- Algorithmen wurden implementiert
- Ergebnisse wurden ausgewertet und verglichen

Anmerkung zu TP 3.1, 3.2, 3.5:

In der Projektlaufzeit ergaben sich neue Entwicklungen im Feld der Objekterkennung, die ganz andere Methoden ermöglichten als noch vor ein paar Jahren [28]. Hierfür wurden gegen Ende des Projektes auch die neuen Methoden im Bereich des Deep Learning betrachtet und ein Ansatz ausgewählt, der zuvor schon in diesem Abschnitt näher erklärt wurde. Dieser hat den Vorteil, dass die Aufgaben von TP 3.1, 3.2 und 3.5 in einem Schritt erledigt werden konnten.

Die Ausgabe ist eine abstrakte Beschreibung der Umwelt, die unter anderem durch die Beschilderung, Informationen zu einer Baustelle liefert:

- Baustelle kommt in x m
- Baustelle beginnt
- Durch Pylonen und Baken gekennzeichnete Änderungen des Fahrbahnverlaufs die durch gelbe Linien (TP 3.6) ergänzt werden.
- Wanderbaustelle, die mittels komplexer Verkehrszeichen auf Anhängern angekündigt werden und ggf. noch nicht in Karten von Navigationssystemen vermerkt sind

TP 3.6

Ein Softwaremodul zur Umfelderkennung in Baustellensituationen pro Teilarbeitspaket. Die Straße wird sowohl auf Markierungen als auch in ihrer Gesamtheit, also der vollständig erfassbaren Oberflächenerscheinung, mittels semantischer Segmentierung erfasst und ausgewertet. Das Ergebnis ist eine semantische und geometrische Beschreibung aller Elemente auf der Fahrbahn mit einer sehr hohen Genauigkeit im Nahbereich. Diese Genauigkeit reicht theoretisch aus, um ein Fahrzeug automatisiert auf einer Spur durch eine Baustelle zu steuern.

AP 4: Systemintegration Domaincontroller und Vernetzung

Aufwand:

Continental (1 PM), CMORE (2 PM), **b-plus (16 PM)**, TÜV-NORD (4 PM), Fraunhofer IAIS (1 PM)

In diesem Arbeitspaket wurden die einzelnen Systemkomponenten zu einer Gesamtanordnung zusammengeführt/integriert. Die *Smart-Sensors* wurden über neuartige breitbandige Vernetzungstechnologien ggf. unter Einsatz einer time-sensitive Switch-Technologie an die zentrale Rechnerarchitektur, eine Prototyping Plattform, angebunden. Die zeitliche Synchronisierung der einzelnen smart Sensoren spielte in diesem Zusammenhang eine exponierte Rolle vor dem Hintergrund der Datenfusion und der Bildung einer Realzeit Umgebungsabbildung. Der Domaincontroller stellte eine anwendungstypische Interfaceumgebung (RTE) zur Verfügung, in der die Algorithmik zielsystemtypisch erprobt werden konnte. Die Architektur wurde für die Erprobung und den Funktionsnachweis des Demonstrators zentral an eine Messanordnung angebunden. Die einzelnen Teilarbeitspakete waren:

- T4.1 Implementierung Vernetzungsarchitektur
- T4.2 Zentrale Recheneinheit mit Prototyping Frameworks, Aufbau und Implementierung
- T4.3 Messanordnung zur Datensammlung
- T4.4 Laboraufbau

b-plus:

Arbeitspaket 4 befasst sich mit der Implementierung der in AP1 definierten Vernetzungsarchitektur, Integration der einzelnen Systemkomponenten in ein Gesamtsystem (Versuchsträger und Laboraufbau) sowie der Anpassung und Implementierung von Funktionen zur Aufzeichnung der Messdaten auf der Messtechnikplattform.

Zu Beginn des Projektes wurden Schritte zur Integration des Prototypen Systems und Software Anpassungen am Ethernet Switches basierend auf den Anforderungen der verwendeten Sensoren durchgeführt. Im Zentrum der Arbeiten stand die Anbindung von fünf 100BASE-T1 Kameras von Continental sowie einer Podbox von CMORE an den Datenlogger. Hierzu wurde eine bestehende Datenlogger-Lösung um diese beiden Geräte erweitert.

Die Zeitsynchronisierungsmechanismen im Switch wurden hinsichtlich der Anforderungen der Kameras erweitert, so dass alle notwendigen Endknoten auf einer gemeinsamen Zeitbasis operieren. Zusätzlich wurden Arbeiten hinsichtlich optimierter Zeitsynchronisations-Mechanismen, welche in Ausbaustufen 2 zur Anwendung kommen, durchgeführt.

Nachdem die Integration des Prototypen Systems und Anpassung des Time-Sensitive Switches beendet waren, wurde eine Fahrzeuginbetriebnahme aller Komponenten erfolgreich

durchgeführt. Der Versuchsträger wurde auf Funktion und Gesamtheit validiert. Hierbei ist die reibungslose Zusammenarbeit mit den Projektpartnern zu erwähnen.

Für Ausbaustufe 2 war der Einsatz eines Messtechnik Adapter notwendig, welcher den Kamera Datenstrom (GMSL2 Datenstrom) in einen Ethernet Datenstrom umwandelt. Der Adapter konfiguriert die GMSL2 SerDes Signalstrecke, mit Serialzer und Deserialzer sowie den Imager. Die Konfiguration und Inbetriebnahme von 2.5 MP Kameras, welche im Versuchsträger verbaut wurden, sowie einer hochauflösenden 8 MP Kamera wurden durchgeführt. Es können gleichzeitig vier 2.5 MP bzw. 8 MP Kameras an einem Messtechnik Adapter betrieben werden. Der Laboraufbau wurde mit fünf 2.5 MP und einer 8 MP Kamera sowie zwei Messtechnik Adaptern erweitert.

Bei den ersten Testfahrten zeigte sich, dass die 2.5 MP Kameras zwingend eine Belichtungssteuerung benötigt. So waren bei hohen Lichtverhältnissen, wie zum Beispiel Sonnenschein und Ausfahrt aus einem Tunnel, die Kameras zu stark belichtet und lieferten nur ein weißes Bild. Eine vom Projektpartner Continental bereitgestellte Belichtungssteuerung wurde in das Datenlogger Framework integriert. Die Messtechnik Adapter wurden hierzu ebenfalls erweitert.

Weiter wurde ein Demo-Projekt erstellt, welches alle aufgezeichneten Daten eines Recordings wieder in seine einzelnen Datenströme aufspaltet. Damit wurde allen Projektpartner die Möglichkeit gewährt auf die aufgezeichneten Daten zu zugreifen und in ihre eigene Toolchain zu integrieren. Das Demo-Projekt wurde sowohl für Linux als auch Windows zur Verfügung gestellt. Durch diese Portierung war es allen Projektpartner möglich die aufgezeichneten Daten weiterzuverarbeiten und als Grundlage für ihre Algorithmen-Entwicklung zu nutzen.

Der Time-Sensitive Switch aus Ausbaustufe 1 wurde für Ausbaustufe 2 durch einen leistungsstärkeren Nachfolger ersetzt. Hierbei waren einige Software Anpassungen notwendig. Dies beinhaltete unter anderem, die Erstellung von Treibern für einen 1000BASE-T1 PHY, der auf der Plattform zum Einsatz kam. Weiter wurde für diesen Automotive Ethernet PHY ein Testinterface implementiert, welches Zugriff auf Testfunktionen des PHYs ermöglichte. Der Projektpartner TÜV Nord nutzte dieses Interface um Layer 1 Tests für 100BASE-T1 sowie 1000BASE-T1 durchzuführen. Zusätzlich nutzte der Projektpartner TÜV Nord den Switch für die in AP5 durchgeführten BER Messungen einer Automotive Ethernet Signalstrecke.

Des Weiteren wurden auf der Switch Plattform Implementierungen von einzelnen Mechanismen zur Absicherung des Netzwerkes bei Fehlverhalten von einzelnen Endknoten, wie z.B. Sensoren, evaluiert. Ein untersuchter Ansatz war dabei der Einsatz von Policern basierend auf dem Token-Bucket-Algorithmus. Ein weiterer untersuchter Ansatz zur Absicherung von Netzwerken vor dem Ausfall einzelner Links oder Switche war ein Redundanzkonzept basierend auf IEEE Std 802.1CB. Dies ermöglicht die redundante Übertragung von Streams über zwei disjunkte Pfade im Netzwerk. Dabei können Switche im

Netzwerk sowohl Daten duplizieren als auch redundante Frames eliminieren. Diese Mechanismen wurden ebenfalls in den Switch integriert und erfolgreich evaluiert.

Für eine effiziente Datenablage war es notwendig das Datenablage Konzept zu erweitern. Die bei einem Recording entstehende Datei ist zur Sicherstellung der Integrität abgesichert. Es ist nicht vorgesehen, dass das Recording selbst modifiziert wird. Daher ist für die Ablage von zusätzlichen Metainformationen zum Recording, die erst nach der Erstellung des Recordings generiert werden, wie z.B. Label Daten, ein zusätzliches Datenablage Konzept notwendig. Hierzu wurde eine Datenbank erstellt in der effizient Label Informationen zu den Daten in den Recordings abgespeichert und wieder ausgelesen werden können. Diese Label Informationen können mit Hilfe der Datenbank in Relation zum aufgezeichneten Datenstrom bzw. der gesamten Aufzeichnung gesetzt werden. Eine genaue Rekonstruktion der aufgezeichneten Fahrt und den zusätzlich abgespeicherten Label Informationen ist somit gegeben.

Auf der Messtechnik Plattform wurde ein Typ-1-Hypervisor aufgesetzt und in Betrieb genommen. Dieser Hypervisor verwaltet den Hardware Zugriff von Virtuellen Maschinen (VMs) und erlaubt es, dass einzelne Hardware-Ressourcen exklusiv einer spezifischen VM zugewiesen werden. Dies ermöglicht eine flexible Konfiguration der Plattform und die parallele Ausführung von z.B. Messtechnik Software und Visualisierung oder Algorithmik. Es wurden mehrere VMs im Zuge des Projektes aufgesetzt, jedoch wurden gleichzeitig immer nur maximal zwei VMs auf der Plattform betrieben. Die Implementierung eines Realtime ECU Frameworks wurde mit Hilfe des erstellten Virtualisierung-Konzeptes auf einer der erstellten VM realisiert.

Ein wichtiger Punkt für die Virtualisierungsumgebung war die Möglichkeit einer genauen Zeitsynchronisation zwischen den einzelnen VMs und zwischen den VMs und einem externen PTP Zeitmaster. Hierzu wurde ein Setup erstellt in dem auf einer Windows VM (mit Datenlogger) eine Zeitsynchronisation-Software ausgeführt wurde, die die Zeit gemäß IEEE 802.1AS synchronisiert. Diese wurde um Mechanismen erweitert, welche es ermöglichen die Zeit an eine andere VM weiterzuleiten. Die zweite VM bestand aus einer VM mit Linux Betriebssystem, sie empfing dabei eine hoch genaue synchronisierte Uhrzeit von der VM mit Windows System.

AP 5: Prototypenevaluierung und Validierung

Aufwand:

Continental (1 PM), CMORE (37 PM), b-plus (2 PM), TÜV-NORD (3 PM), Fraunhofer IAIS (1 PM)

Im Bereich der Homologation selbstfahrender Fahrzeuge, die auf einer Ethernet-Bordnetzwerkarchitektur basieren, sollten standardisierte Testmethoden zur Verfügung gestellt und durchgeführt werden.

Das Ergebnis dieses Arbeitspaketes umfasst die Überarbeitung von Teststandards im Bereich Validierung basierend auf den neuen Anforderungen in Richtung Hoch- und vollautomatisierten Fahren.

Dazu gehörten die Erstellung von angepassten funktions- und situationsabhängigen Key Performance Indikatoren (KPIs) und die Bewertung dieser, in Verbindung mit der Anwendung der ausgearbeiteten Standardtestmethoden.

Abschließend erfolgte eine qualitative Analyse der eingesetzten Verfahren bezüglich Anwendbarkeit der innovativen Methoden auf ähnliche Szenarien und ein Ausblick auf Verbesserung und Anpassung dieser für weitere Applikationen zum autonomen Fahren.

Der TÜV-Nord führte abschließend eine Auswertung und Bewertung des Testkonzepts, der Testergebnisse und des Gesamtsystems hinsichtlich der aufgestellten Systemanforderungen durch. Darüber hinaus wurden relevante Anforderungen hinsichtlich Serienzulassung, Typgenehmigung und periodisch-technischer Überwachung abgeleitet.

Zur Umsetzung wurde im Wesentlichen die Anforderungsanalyse und Architektur aus AP1, umgesetzte Sensorfunktionen aus AP3, Fahrzeugaufbau aus AP2 und die integrierte Anwendung aus AP 4 benötigt. Das AP5 setzt sich ausfolgenden Teilarbeitspaketen zusammen:

- TP5.1: Konzept und Planung der Validierung
- TP5.2: Definition der KPIs und Abstimmung Toolkette
- TP5.3: Planung und Durchführung und Fahrzeugtests
- TP5.4: Analyse Fahrzeugtests und KPI Erstellung
- TP5.5: Bewertung hinsichtlich Systemanforderungen und Serienzulassung

CMORE:

Detaillierung TP 5.1 Konzept und Planung der Validierung

In enger Abstimmung mit dem Partner TÜV Nord erfolgte die Erarbeitung eines Validierungskonzeptes. In Diskussionen und Untersuchungen wurden die Test- und Validierungsbereiche eingegrenzt. Ausgangspunkt war die Festlegung, dass das AutoConstruct-System in realer Einsatzumgebung und Situation erprobt werden soll.

Zunächst sollte der Test in folgenden drei Bereichen erfolgen:

- 1- Erkennung von Baustellenschildern
- 2- Erkennung der Baustellenobjekte (Leitbaken, Kegel, Wände, etc.)
- 3- Positionierung.

Es schlossen sich Überlegungen in Bezug auf den grundlegenden Testumfang (zu testende Bereiche) an. Hier wurde zunächst festgelegt, dass sich die Prüfungen auf reale Szenarien in Baustellen konzentrieren und gestellte Szenarien nur für Sonderprüfungen eingesetzt werden sollen. Davon ausgehend wurden (in Abstimmung mit den Partnern) folgende Prüfgebiete als prioritär erachtet:

- Der Test muss die Tagesperioden berücksichtigen (Sonnenaufgang, Mittag, Sonnenuntergang, Nacht)
- Prüfung durch Fahren ohne kritische Wetterbedingungen (z. B. Schnee, Regen, Nebel, niedrige Sonne)
- Alle relevanten Baustellenobjekte und Schilder
- Holprige Straßen

Vom Test grundsätzlich ausgeschlossen wurden extreme Umgebungssituationen, wie extreme Stürme, Hagel, Überschwemmungen etc.

Darauf aufbauend wurde ein konsistentes Test- und Validierungsmodell sowie die Validierungsszenarien herausgearbeitet (□) und Validierungsziele (•) definiert:

- KS1 – Baustellenerkennungsrate
 - Korrekte Erkennung in einer Baustelle: >90 %
 - Korrekte Erkennung keiner Baustelle: >95 %
- KS2 – Erkennung von komplexen Verkehrszeichen
 - Korrekte Erkennung: >80 %
 - Verwechslungen: <10 %
 - Falsch Positive: < 1 pro 20 km
- KS3 – Erkennung und Positionsgenauigkeit relevanter Baustellenobjekte
 - Korrekte Erkennung: >90 %

- Falsch Positive: < 1 pro 20 km
 - Abstandsfehler (Euklidischer Abstand zw. Kamera und Baustellenobjekt): <10 %
 - Winkelfehler < 0,5°
- KS4 – Positionsgenauigkeit relevanter Spurmarkierungen und Baustellen
 - Abstandsfehler (Euklidischer Abstand zw. Kamera und Baustellenobjekt): <10 %
 - Winkelfehler < 0,5°
 - KS5 – Verfügbarkeit Spurmarkierungen
 - Verfügbarkeit: > 90 %
 - Maximaler Zeitraum ohne Verfügbarkeit: < 2s

Damit wurde folgender methodischer Ansatz abgeleitet:

- Die Grundlage für die Vergleichsdaten („ground truth“) liefern Bilddaten, in denen Baustellen durch Label eindeutig identifiziert wurden. Baustellen werden framebasiert klassifiziert, weshalb für die Validierung eine bestimmte Anzahl an Frames mit den entsprechenden Metadaten (Klassifikation, etc.) zur Verfügung stehen müssen.
- Die Objektvalidierung wird in drei Bereiche eingeteilt: Objekte zwischen 256px-500px, 500px-2000px und größer als 2000px.
- Es wurden konsistente Festlegungen für das Testumfeld erarbeitet (bspw. Positionen relevanter Baustellenobjekte)
- Für die Validierung der Kamerakalibrierung war wichtig, eine felddaugliche Lösung zu finden. Bei erwartetem erheblichem Testumfang musste gewährleistet sein, dass unterwegs nachkalibriert werden kann. Favorisiert wurde das Ziehen von Kreisen um die Kameras (z. B. mit „Stock und Faden“) und das Prüfen der Ausgabe entlang dieser Linien.

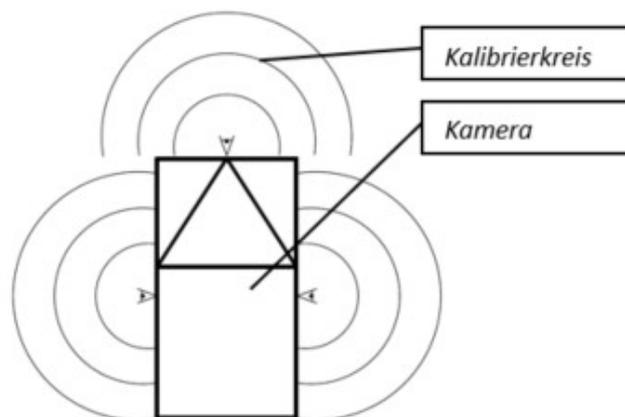


Abbildung 74: Felddauglicher Kalibrierungsansätze

Darauf aufbauend wurde eine detaillierte mathematische Untersetzung des Validierungsansatzes vorgenommen. Es ist bekannt, dass der Umfang der einzufahrenden (Referenz) Daten direkt von der erwarteten Aussagekraft der Daten abhängt. In der Vorhabenbeschreibung (Tabelle 6) waren bereits Erwartungen an die Aussagekraft der Daten definiert. Weiterhin gingen die Betrachtungen davon aus, dass eine exakte Aussage über die Wahrscheinlichkeit eines Ereignisses nur durch eine unendlich lange Messung erreichbar ist. In der Praxis werden daher Messungen anhand von Stichproben bzgl. eines Signifikanzniveaus durchgeführt. Im Automotive Bereich ist es gängige Praxis, Messergebnisse mit einer Signifikanz von 95 % anzugeben. Mit diesen Werten wurde eine Mindestgröße an Messungen (Stichprobenumfang N) bestimmt, die notwendig ist, um eine bestimmte Eintrittswahrscheinlichkeit eines Ereignisses nachweisen zu können.

Der Stichprobenumfang N für beispielsweise einen Leitkegel (KS4 – Erkennen von Baustellenobjekten) ergibt sich aus 75 Messungen für die geforderte Signifikanz von 95 %. Um die weiteren Variationen abzudecken, wird dieser Wert für die Lichtverhältnisse Tag und Nacht mit dem Faktor 2, und dem Faktor 3 für drei verschiedene Größenbereiche, in denen der Leitkegel erkannt werden muss, multipliziert. So ergibt sich am Ende ein geforderter Stichprobenumfang N von $75 \cdot 2 \cdot 3 = 450$ Messungen pro relevantem Baustellenobjekt.

Die Berechnung des Stichprobenumfangs für die weiteren KPIs (Erkennen von komplexen Verkehrszeichen, Spurmarkierungen) setzt sich auf ähnliche Art und Weise zusammen.

Zusätzlich ergab sich für die Auswertung von False Positives ein Testumfang von 1.200 km.

Damit war die Validierung grundsätzlich vorbereitet. Im Weiteren wurde dies nun (in Abstimmung mit den Partnern) entsprechend detailliert (z. B. sind farbliche Unterscheidungen von Spurmarkierungen relevant? Muss bei komplexen Verkehrszeichen auch der Inhalt erkannt/klassifiziert werden?).

Auch wurden charakteristische Baustellenszenarien detailliert untersucht und beschrieben. Nachfolgend ist beispielhaft eine solche Szene gezeigt.

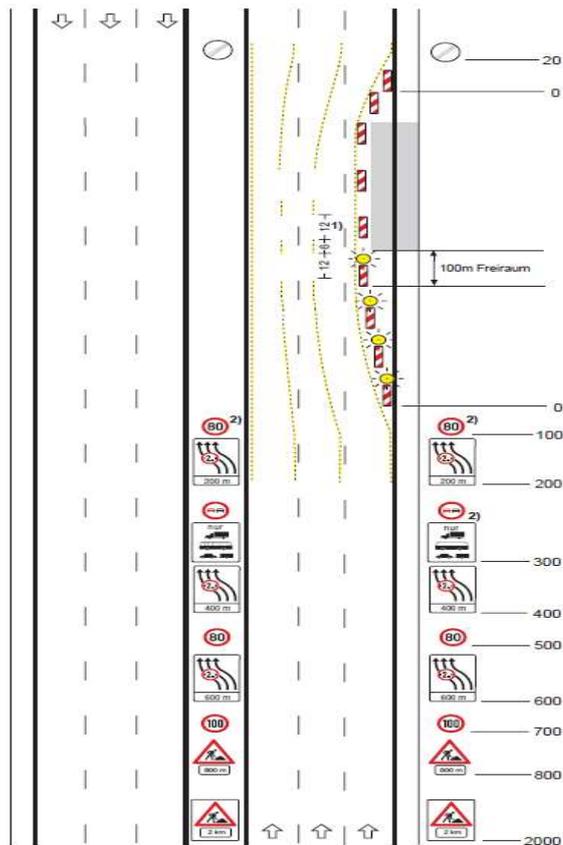


Abbildung 75: Beispielhafte Baustellenszene

Das System soll die Schilder erkennen und dass es sich um eine Baustelle von längerer Dauer handelt (abzuleiten davon, dass Schilder bereits 2 km im Vorlauf aufgestellt sind). Konkrete Testaufgabe im Projekt ist die Erprobung neuer Kameras und Algorithmen für Sensorfusion und Objekterkennung sowie das Testen unter unterschiedlichen Umweltbedingungen in einem realen Umfeld.

Mit der erarbeiteten Menge an Standard-Szenarien konnte mit den Tests begonnen werden.

Im weiteren Verlauf wurden weitergehende Optimierungspotenziale in folgenden Punkten eruiert:

Allgemein:

- Funktionalität bei Nacht
- Definition komplexes Verkehrszeichen
- Welches Equipment steht auf dem Continental Testfeld zur Verfügung? (Baustellen relevante Objekte...)

Baustellenobjekte:

- Identifizierung
- Attribute

Spurerkennung:

- Attribute
- Ausgabe der Spur

Im finalen Validierungskonzept konnten noch Einsparungen im Testaufwand identifiziert werden:

- Für KPIs, deren Fehlerrate in “1/20km” getestet werden sollte, wurde dank der “Rule of Three” der notwendige Datenumfang um den Faktor 10 verringert.
- Bei KPIs in % konnte oftmals der Umfang auszuwertender Frames um Faktor 2 bis 6 gesenkt werden, da Multiplikatoren eliminiert werden konnten (z. B. durch Verteilung des Umfangs auf verschiedene Szenarien, anstatt für jedes Szenario den gesamten Aufwand einzufahren oder durch Einführung von Objektclustern).

Die Ausführungsbestimmungen für die Tests auf dem Testgelände wurden fertiggestellt und die benötigten Materialien definiert.

Detailierung TP 5.2 Definition der KPIs und Abstimmung Toolkette

Ein wichtiges Ziel war hier die Optimierung der Zusammenstellung der Stichproben und die Qualitätssteigerung durch das ständige Erfassen von KPIs für den Labelprozess. Hierzu wurde zunächst eine Folgeabschätzung für nicht erkannte Zeichen erstellt:

Verkehrszeichen	Zeichenname	Nummer	Symbol	Mögliche Konsequenzen wenn ein Zeichen übersehen werden					
				StVO Verstoß	Personenschadef	Fahrzeugschadef	Baustellenschaden	Umwelteinflüss	
Gefahrenzeichen	Kreuzung	102			+++	+++	+		
	Kurve	103			+++	+++	+++		
	Gefälle	108				+			
	Steigung	110				+			
	Stau	124			+++	+++			
	Bodenwellen	112				+			
	Straßenverengung	120			+++	+++	+++		
	Doppelkurve	105			+++	+++	+++		
	Gegenverkehr	125			+++	+++	+++		
	Richtzeichen	Numerierte Umleitung	455-1						+
		Ende der Umleitung	455-2						+
		Ankündigungsbake	450						+
Bedarfsumleitung		460						+	
Überleitung auf die andere Fahrbahn		500			+++	+++	+++		
Überleitung auf die andere Fahrbahn mit Verengung		515		+++	+++	+++	+++		
Einengung mit Gegenverkehr		532			+++	+++	+++		

Abbildung 76: Systematisierung von Konsequenzen, wenn Zeichen übersehen werden

Weiterhin wurden Tags für das Online-Tagging definiert, welche Tagesbaustellen und Dauerbaustellen unterscheiden und verschiedene Schilder und Zusatzzeichen abdecken. Des Weiteren wurden signifikante Situationen des Spurverlaufes und die Lichtverhältnisse getaggt. Der genaue Umfang ist in der nachfolgenden Abbildung zu erkennen:

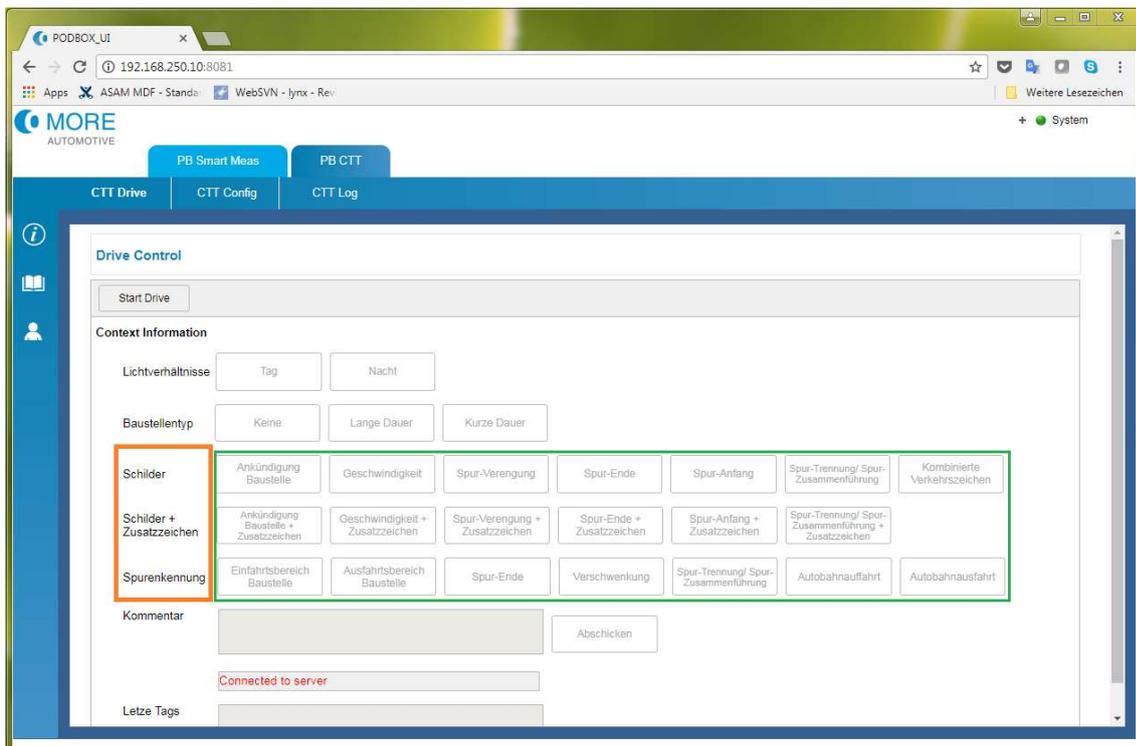


Abbildung 77: PODBOX-Oberfläche zum Online Tagging

Ausgehend von den Ergebnissen in AP 5.1 wurden, in Abstimmung mit den Partnern, die zu validierenden Attribute im Detail festgelegt und daraufhin der Stichprobenumfang und das Vorgehen der Auswertung der Daten weiter verfeinert. Dabei haben sich Änderungen bei der

Validierung des KS4 – Positionsgenauigkeit relevanter Spurmarkierungen ergeben. Die Validierung für KS4 gliederte sich nun wie folgt:

- TP (Erkennung Spur) > 90 %
- Abstandsfehler < 10 %
- Winkelfehler < 0,5°
- Abstandsfehler bei Schräglage des Fahrzeugs < 10 %

Es wurde abgestimmt, dass die Festlegung einer Spur nur durch Fahrbahnmarkierungen geschieht. Eine Festlegung der Spur durch bauliche Objekte wie Pylonen oder Baken gibt es nicht.

Bisher war für den Abstands- und Winkelfehler in KS4 angegeben, dass keine weitere Referenz benötigt wird und die Überprüfung der Kamerakalibrierung ausreichend ist. Diese Überprüfung wurde in einem aktualisierten Konzept fallen gelassen. Die Validierung von Abstand und Winkel wurde auf dem Testfeld durchgeführt, um Fehler bei der Kamerakalibrierung oder den Einfluss der Fahrzeugbewegung zu untersuchen.

Folgende Attribute werden validiert:

- Abstand (Relativposition zum Fahrzeug)
- Winkel ψ

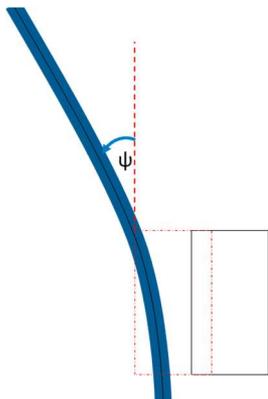


Abbildung 78: Erklärung Winkel

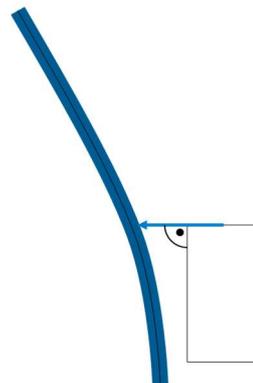


Abbildung 79: Erklärung Abstand

Für die Bestimmung des Abstands war der Mittelpunkt der Vorderachse der Bezugspunkt am Fahrzeug. Die Erkennung der Spur in KS4 wurde im realen Straßenverkehr validiert, wobei gelabelte Bilder als Referenz verwendet wurden. Die Validierung erfolgte unter Einbeziehung aller erkannten Spuren; nicht nur der Ego-Spur.

Dabei wurden folgende Attribute validiert:

- Markierungstyp
 - durchgezogene Linie
 - gestrichelte Linie
- Farbe
 - weiß
 - gelb

Bei schneller Kurvenfahrt kann das Fahrzeug in Schräglage geraten und dadurch ergeben sich dann trotz korrekter Kamerakalibrierung Fehler für den Abstand, da die gesehene Position von der tatsächlichen Position abweicht. Diese Situation ist schematisch in der nachfolgenden Abbildung dargestellt.

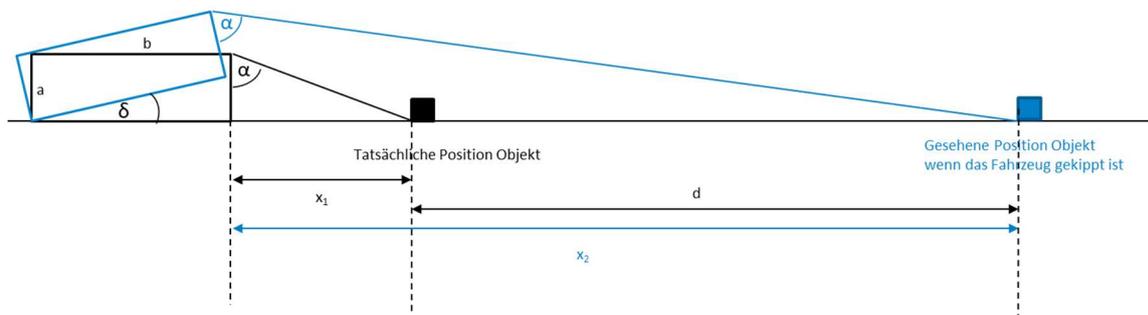


Abbildung 80: Ansicht Fahrzeug von hinten Normalzustand und in Schräglage

Um eine erste Einschätzung über den Einfluss der Fahrzeugkipfung auf die Positionsgenauigkeit zu erhalten, wurden mathematische Berechnungen angestellt, die im Weiteren dargestellt sind. Die tatsächlichen Auswirkungen in der Realität wurden auf dem Testgelände überprüft.

- Die Abweichung zwischen der tatsächlichen Position des Objekts (schwarz) und der gesehenen Position eines Objekts (blau), wenn das Fahrzeug in Schräglage kommt, kann in Abhängigkeit von x_1 und δ berechnet werden.
- Die relative Abweichung $(x_2-x_1)/x_1 \cdot 100$ gibt die prozentuale Abweichung zwischen x_1 und x_2 für verschieden Kippwinkel δ des Fahrzeugs und verschieden Abstände zum Objekt x_1 an und ist in der nachfolgenden Tabelle dargestellt.

$\delta \backslash x_1$	0,1	0,25	0,5	1	2	3	4	5	6	7	8	9	10
0,1	0%	0%	0%	1%	1%	1%	1%	1%	2%	2%	2%	2%	2%
0,25	1%	1%	1%	1%	2%	2%	3%	3%	4%	4%	5%	5%	6%
0,5	2%	2%	2%	3%	4%	5%	6%	7%	8%	9%	10%	11%	12%
1	4%	4%	5%	6%	8%	10%	12%	15%	17%	19%	22%	25%	28%
2	9%	9%	10%	12%	16%	21%	27%	32%	39%	46%	54%	63%	72%
3	15%	14%	15%	18%	26%	34%	44%	55%	68%	84%	103%	126%	155%
4	21%	19%	21%	25%	36%	49%	65%	85%	110%	144%	189%	257%	365%
5	28%	25%	27%	32%	47%	66%	91%	125%	174%	249%	382%	678%	1913%

Tabelle 6: Prozentuale Abweichung zwischen x_1 und x_2

Dabei sind die Werte für a und b fest und entsprechen mit $a = 0,9$ m (Höhe der angebrachten Kamera) und $b = 2$ m (Abstand zwischen Kameras auf der rechten bzw. linken Seite des Fahrzeugs) der Anordnung in der Realität. Für größer werdenden Kippwinkel δ und größer werdende Distanz zum Objekt x_1 steigt jeweils die relative Abweichung.

Ursprünglich war als Ziel definiert, dass eine Positionsgenauigkeit mit Abweichungen von max. 10 % erreicht werden soll. Ausgehend von diesem Projektziel wurden alle Abweichungen < 10 % in Tabelle 6 grün markiert.

Zur Überprüfung der berechneten Werte wurde im weiteren Verlauf auch noch eine Validierung der Positionsgenauigkeit für verschiedene Kippwinkel des Fahrzeugs durchgeführt. Dies erfolgte im statischen Zustand, da nur so der Kippwinkel durch definiertes Kippen des Fahrzeugs exakt eingestellt werden kann.

Im Zuge der Finalisierung des Validierungskonzeptes wurden auch die KPIs abschließend definiert. Insbesondere wurde für die Berechnung der KPIs das Analysetool-Requirement festgelegt, sodass die Berechnung der KPIs durch das Analysetool anforderungsgemäß erfolgen konnte.

Für die Speicherung und Verarbeitung der aufgenommenen Daten wurde die CMORE-Lösung C.DATA genutzt.

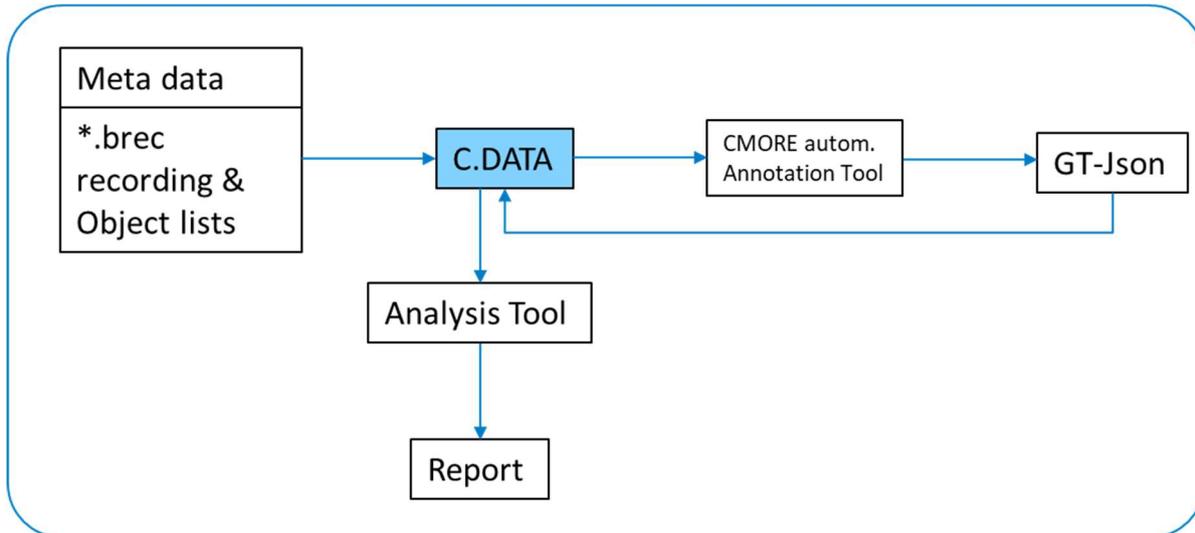


Abbildung 81: Analyseprozess für Baustellenobjekte

C.DATA ist eine Plattform für die integrierte Entwicklung und Validierung autonomer Mobilität. Ziel dieser Plattform ist die Effizienzsteigerung des Entwicklungs- sowie Testprozesses. Im Rahmen des Projektes AutoConstruct wurden die eingefahrenen Daten geprüft und ein Konzept für die Registrierung der Daten auf der Plattform entwickelt. Die Daten werden über ein Import-Plug-in in der Datenbank der Plattform registriert und gleichzeitig mit den Meta-Informationen der PODBOX verknüpft. Dies führte im ersten Schritt zu den nachfolgend beschriebenen Vorteilen:

- **Information über Meta-Daten:**

über die Recording-Liste der Plattform können alle registrierten Recordings und mit diesen auch die verknüpften Meta-Informationen über einen Mausklick gesehen werden.

Beispiel: Das Recording „bdaq_recording_20180430“ beinhaltet eine Tagesbaustelle von Kilometer 40 bis Kilometer 42.

- **Filtern von Recordings:**

über die Suchfunktion können die Recordings nach Meta-Informationen gefiltert werden.

Beispiel: Suche nach allen Recordings, die eine Dauerbaustelle beinhalten.

- **Analysieren und Visualisieren von Recording-Fakten:**

über das C.DATA Reporting Dashboard können die Recordings auf verschiedene Faktoren hin analysiert und die Ergebnisse visualisiert werden.

Beispiel: Analyse der Kilometer, die innerhalb des Projektes gesamt oder innerhalb

von Dauerbaustellen gefahren wurden. Visualisierung der Analyseergebnisse in Diagrammen.

Detaillierung TP 5.3 Planung und Durchführung und Fahrzeugtests

Vor der finalen Validierung wurden zu Test- und Verbesserungszwecken einige Validierungsloops durchgeführt. Dabei wurde zum einen die Analysetoolkette auf Funktionalität geprüft, zum anderen die Möglichkeit genutzt, die Performance der zu entwickelnden Algorithmik zu prüfen und Verbesserungspotentiale aufzuzeigen. So wurde durch Online-Datenstreaming die Voraussetzungen geschaffen, Probleme mit der Messtechnik während der Probefahrt zu identifizieren, wodurch das Risiko, invalide Daten in größeren Mengen einzufahren, reduziert wurde.

Im Rahmen der Erarbeitung des Validierungskonzeptes wurde auch der genau benötigte Testumfang festgelegt. Der Fahraufwand im öffentlichen Straßenverkehr wurde auf 10 Arbeitstage sowie 2 bis 3 Tage Spezialtests auf einem Testfeld geschätzt.

Hierbei wurde darauf geachtet, dass neben Tagaufnahmen auch Dämmerungs- und Nachtfahrten durchgeführt werden, um die Performance der eingesetzten Kameras auch unter schwierigeren Bedingungen zu testen.

Detaillierung TP 5.4 Analyse Fahrzeugtests und KPI Erstellung

Die Datenanalyse wurde toolgestützt durchgeführt, da eine genaue, manuelle Auswertung von mehreren 10.000 Frames weder praktikabel noch wirtschaftlich sinnvoll ist.

Hierzu wurden zwei Tools entwickelt:

Das erste Tool ist spezialisiert auf die Auswertung der KS1 – KS3, also Baustellenobjekten. Mittels eines Intersection over Union (IoU) Wertes von mindestens 0,6 werden zu-einander passende reale und algorithmisch ermittelte Objekte identifiziert („Matching“) und deren Attribute miteinander verglichen.

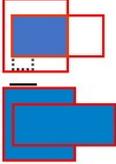
$$Intersection\ over\ Union\ (IoU) = \frac{Area\ of\ Overlap}{Area\ of\ Union} = \frac{A \cap B}{A \cup B}$$


Abbildung 82: Intersection over Union

So kann die Anzahl der algorithmisch gefundenen Objekte festgestellt sowie deren Klassifikation überprüft werden.

Ein zweites Tool wurde dafür verwendet, Spurmarkierungen miteinander zu vergleichen. Im Gegensatz zum ersten Tool kamen keine rechteckigen „Bounding Boxen“ zum Einsatz, sondern Polygonzüge, da sonst die Verläufe von Spurmarkierungen nicht ausreichend abgebildet werden können. Da Continental die Ausgabe von 4 Kameras fusioniert und diese in die Vogelperspektive transformiert, um eine bestmögliche Erfassung der vorhandenen Markierungen zu gewährleisten, musste auch das von CMORE entwickelte Tool diese Transformation nachbilden. Das Matching wurde hierbei nicht gemäß dem IoU Ansatz realisiert, da dieser für längliche Objekte eher ungeeignet ist. Stattdessen wurden die Abstände der Mittellinie der Spurmarkierung zwischen den Continental- und den CMORE-Daten bewertet. Mit zunehmender Distanz zum Testfahrzeug wurden dabei größere Abstände toleriert.

Zur Bewertung der Algorithmen von Continental und Fraunhofer wurden „Echt-Daten“ bzw. Ground Truth (GT)-Daten als Referenz benötigt. Die erforderlichen Daten wurden von CMORE selbst erzeugt und bereitgestellt.

Um Fehleinschätzungen in der Validierung auszuschließen, wurden die automatisiert erzeugten GT-Daten für die Baustellenobjekte noch einer Qualitätskontrolle unterzogen, bei der vorhandene Fehler gelöscht werden.

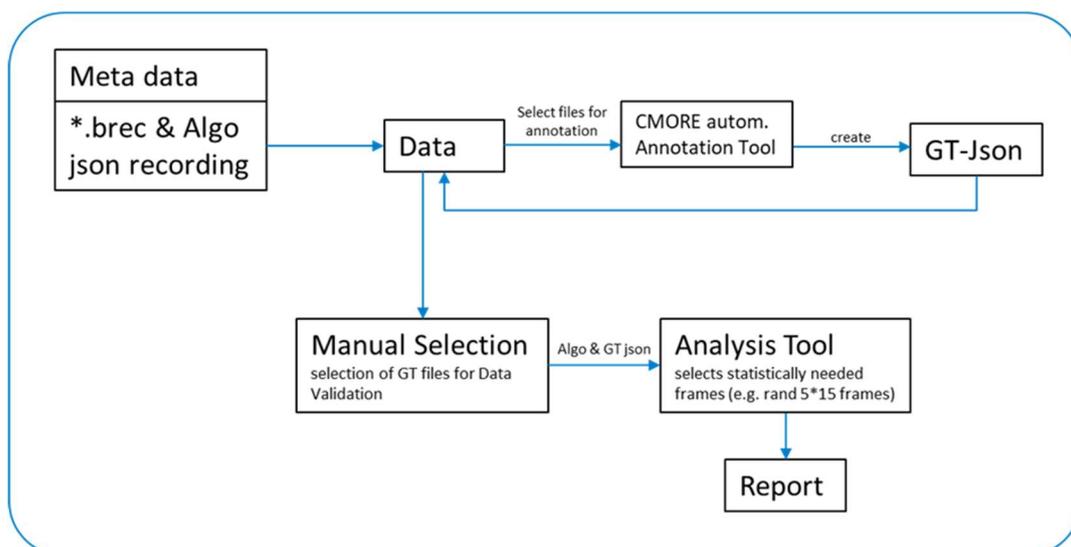


Abbildung 83: Prozess der Datenanalyse und GT-Bereinigung für Baustellenobjekte

Die Bereitstellung der GT-Daten für die Spurmarkierungen wurde ebenfalls von CMORE übernommen. Hierbei kam allerdings manuelles Labeling zum Einsatz, weshalb keine weiterführende Qualitätskontrolle notwendig war.

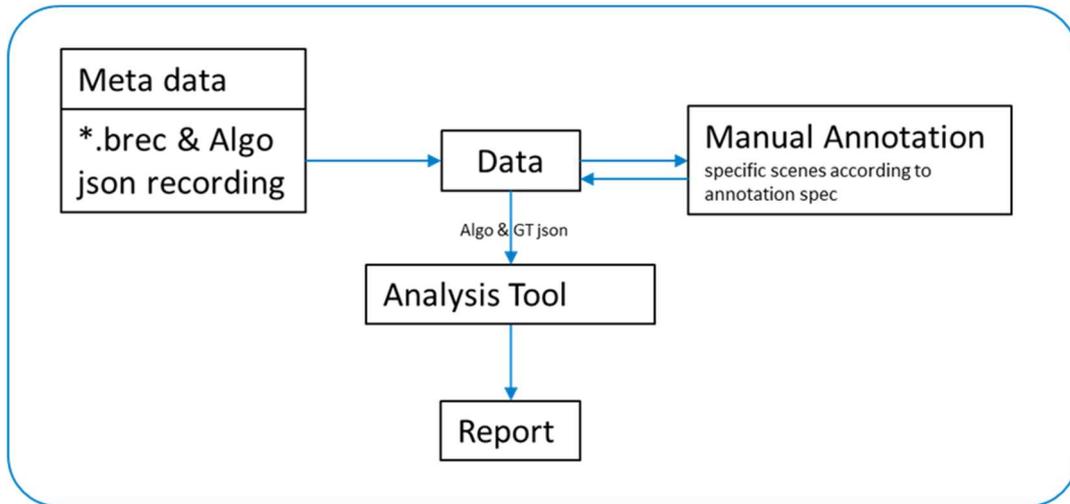


Abbildung 84: Prozess der Datenanalyse für Spurmarkierungen

Detaillierung TP 5.5 Bewertung hinsichtlich Systemanforderungen und Serienzulassung

Im Rahmen dieses Teilarbeitspaketes hat CMORE umfangreiche Arbeiten auf folgenden Gebieten durchgeführt:

- Systematisierung der Testergebnisse anhand der Anforderungsklassen
- Spiegelung am Gesamtkonzept (grundsätzliche Zielerfüllung)
- Bewertung einzelner Teilfunktionen bezüglich ihres Erfüllungsgrades
- Ableitung von Kriterien mit Bezug auf späteren Serienzulassung
- Validierung derselben

Durch die Ergebnisse aus diesem Arbeitspaket und dem Projekt AutoConstruct insgesamt konnte bei CMORE wichtiges Know-how aufgebaut werden. Einige Beispiele:

- Klareres Verständnis über die Notwendigkeit detaillierter KPI-Definition unter Berücksichtigung des späteren Anwendungsfalles
- Tiefere Einblicke in stochastische Methoden und deren Nutzen bei der Validierung bzw. Testumfangsreduktion durch Stichproben
- Neue Einblicke in die mögliche Komplexität und Anforderungen von Baustellen
- Entwicklung zweier Validierungstools

Dieses Know-how kann bereits in weiterführenden Kunden- aber auch Forschungsprojekten genutzt werden.

2.2 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Im Verbundprojekt AutoConstruct wurden die Forschungsaktivitäten an die Ziele des Förderprogramms ausgerichtet. Grundlage der Arbeiten war unter anderem die Untersuchung von Anforderungen, konzeptioneller Methoden und Ableitung von Lösungsvorschlägen zur Entwicklung von Systemarchitektur und Systemsicherheit beim hoch- und vollautomatisierten Fahren.

Die Berücksichtigung sicherheitstechnischer Anforderungen und die Umsetzung durchgängiger Sicherheitsprozesse im gesamten Entwicklungs- und Produktlebenszyklus ist grundlegende Voraussetzung zur Erreichung eines hinreichenden Technologiereifegrads bei der Entwicklung von Applikationen des hoch- und vollautomatisierten Fahrens.

Aufgrund des Zieles teil-autonom (später voll-autonom) zu fahren ist es unumgänglich Baustellen sicher und mit hoher Güte zu selektieren. Nur so ist es möglich, die Kontrolle wieder rechtzeitig an den Fahrer übergeben zu können oder in nächster Stufe Baustellen Autonom zu durchfahren.

Die sichere Erkennung von Baustellen dient auch der präventiven Unfallverhütung.

Bisher wurden die Baustellenerkennung und der Umgang mit solchen noch wenig erforscht. Da es auch in Zukunft vermehrt zu Baustellen kommen wird ist hier ein unumgänglicher Use Case gegeben. Im Projekt wurde hier ein prototypischer Ansatz implementiert und klassifiziert, an dem angeknüpft werden muss.

Die bisherigen Spurführungsfunktionen werden heutzutage üblicherweise in Baustellenbereichen abgeworfen. Hier ist eine Weiterentwicklung für die Belange in Baustellenszenarien, wie sie hier prototypisch implementiert wurde, auf den Weg zu L5 unabdinglich.

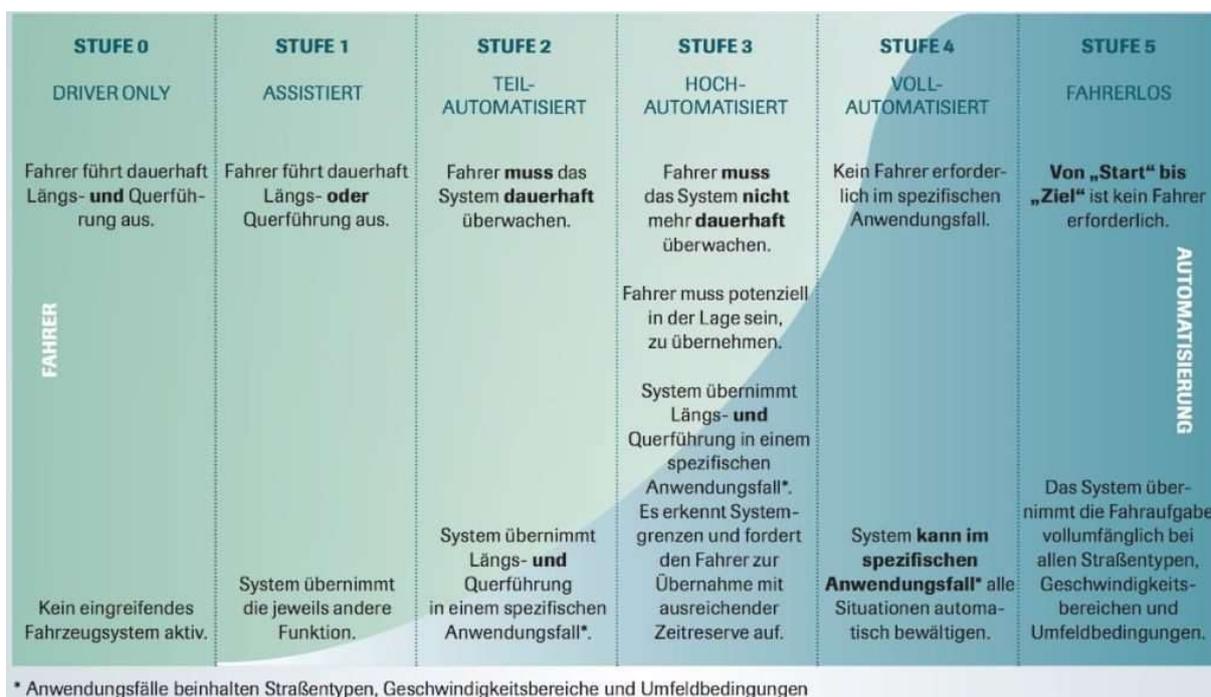


Abbildung 85: Autonomes Fahren: Die Infografik des VDA gibt einen Überblick [38]

Um eine Serientauglichkeit herstellen zu können muss das Konzept auf weitere Länder ausgebreitet und angepasst werden, da z. B. die Beschilderung und Spurführung hier anders aussehen kann. Darüber hinaus sollte das bisherige Konzept im Rahmen eines Serienvorentwicklungsprojektes weiter vertieft werden. Konkret geht es um weitere Varianten von Baustellen in jeglicher Situation. Jedoch bleibt das Basiskonzept (z.B. CNNs, Edge Linking Detection), wie hier in diesem Projekt demonstriert, immer gleich.

2.3 Nutzen/Verwertbarkeit des Ergebnisses

b-plus:

b-plus entwickelt Hard- und Software sowie entwicklungsbegleitende Werkzeuge für Fahrzeugmesstechnik, Fahrerassistenzsysteme (ADAS) und Onboard-Computersysteme. Mit der Entwicklung des autonomen Fahrens, steigen die Anforderungen an die Fahrzeugmesstechnik stark an. Es müssen wesentlich höhere Datenraten von einer wesentlich größeren Anzahl an Sensoren erfasst werden. Um diese Anforderungen zu erfüllen sind neue Messtechnik Konzepte notwendig. Im Rahmen des Projektes entstand ein vernetztes leistungsfähiges und skalierbares Messtechnik System. Zentraler Knotenpunkt ist dabei ein

Ethernet Switch. Dieser verteilt die notwendigen Daten an eine hoch performante Prototypenplattform sowie die Fahrzeugmesstechnik. Eine genaue Zeitsynchronisation kann sowohl nativ auf den Systemen als auch in einer virtualisierten Umgebung sichergestellt werden. Dieser komplette Systemverbund aus Prototypen Plattform, Ethernet Switch und Messtechnik soll zukünftig als Produkt angeboten werden.

Die Ergebnisse sind somit im Sinne des Verwertungsplans verwertbar und werden sowohl Grundstein für zukünftige Forschungsaktivitäten sein als auch in die Produktentwicklung überführt werden. Es sollen dabei sowohl bestehende Produkte erweitert und verbessert werden als auch neue Produkte wie ein Ethernet Switch, sowie weitere innovative Messtechnik Produkte entstehen.

Continental:

Die Ergebnisse aus dem Projekt AutoConstruct werden von Continental weiterhin für Baustellendemos mit OEM (Original Equipment Manufacturer) Kunden verwendet mit dem Ziel der Vertiefung der Vorentwicklung und einer späteren Serienentwicklung.

Ferner können die aktuellen Ergebnisse in bereits existierende Serienfunktionen wie z.B.: Road Edge Detection (Straßenrand Erkennung und Verkehrszeichenerkennung) integriert und erweitert werden.

Bisherige Detektionselemente/Features (z.B. spezifische Fahrbahnmarkierung, Spur/Farbvariationen) sollen erweitert werden, um diese z.B. auch in anderen Ländern zur Verfügung stellen zu können.

Die gewonnenen Erkenntnisse seitens der Messtechnik in diesem Projekt werden in anderen ADAS Projekten auch weiterhin verwendet und weiter ausgebaut.

Fraunhofer:

Im Rahmen dieses Projekts wurden vom Fraunhofer IAIS Algorithmen zur Erkennung von verschiedenen Baustellenobjekten entwickelt.

Zum einen wurde auf Vorarbeiten von Formdetektoren auf Basis von klassischer Bildverarbeitung aufgesetzt und diese weiterentwickelt. Die effiziente Umsetzung der Formdetektoren in hardwarenaher Programmierung erlaubt den Einsatz auf ressourcenärmeren Mikroprozessoren. Eine Verwertung der Formdetektoren ist vor allem bei geschlossenen ADAS Modulen, z. B. der Verkehrszeichenerkennung zur Unterstützung des Fahrers möglich. Die optimierten Formdetektoren wurden entsprechend des Verwertungsplans in eine eigene Softwarebibliothek eingepflegt.

Zum anderen wurden moderne Architekturen von Neuronalen Netzen exploriert, die höherer Rechenleistung bedürfen, aber auch genauere und robustere Ergebnisse erreichen können.

Die dabei entwickelte Technologie zur Verkehrszeichenerkennung ist auch auf weitere fahrrelevante Objekte ausweitbar und ist somit für den kompletten Perzeptionsbereich des autonomen Fahrens anwendbar. Auch Teile dieser Entwicklung sind in eine eigene Softwarebibliothek eingepflegt worden.

Darüber hinaus wurde eine Speziallösung zur Erkennung von Spurführungszeichen entwickelt. Nach dem Wissen des Autors, besteht für diese Spezialbeschilderung noch keine Lösung, woraus sich ein hohes Potential zur Verwertung ergibt.

Die gesammelte Erfahrung im Projekt wird synergetisch in andere Industrie- und Forschungsprojekte einfließen. Darüber hinaus können auf den Ergebnissen, neue Projektpartner gewonnen werden.

TÜV NORD Mobilität:

TÜV NORD Mobilität hat im Verbundprojekt AutoConstruct technologische Anforderungen, methodische Verfahren und Umsetzungskonzepte entwickelt, die in der Entwicklung und Validierung von Systemgruppen für Fahrerassistenzsysteme (FAS) und automatisierten Fahrfunktionen (AF) angewendet werden können.

Eine ganzheitliche Betrachtung der Systemsicherheit und möglicher Fehlerursachen bildet die Grundlage eines geeigneten Nachweiskonzepts für automatisierte Fahrfunktionen. Etablierte Sicherheits- und Technologiestandards sowie methodische Lösungen zur Sicherheitsanalyse und Systemvalidierung sind auf die Anforderungen konventioneller E/E-Systeme für manuell gesteuerte Fahrzeuge ausgelegt. In der Zusammenarbeit mit den Fachexperten der AutoConstruct Konsortialpartner aus unterschiedlichen Disziplinen, wie z.B. Sensorik, Funktionsentwicklung, Funktionsvalidierung, KI-Forschung, Vernetzungsarchitekturen und Sicherheitstechnik hat sich gezeigt, dass in den gegenwärtigen Prozessen zur Forschung und Entwicklung keine durchgängige Betrachtung der Systemsicherheit etabliert ist. Dies erschwert die Argumentation eines Sichernachweises für FAS und AF ungemein und zieht zudem hohe Aufwände nach sich. Sofern Systemsicherheit nicht bereits in der Konzeptphase und in frühen Phasen der System- und Funktionsentwicklung von automatisierten Fahrzeugen berücksichtigt wird, werden nachträglich unnötige Aufwände im Re-Design und verlängerte Entwicklungszeiten nicht zu vermeiden sein.

Die Argumentation der Systemsicherheit für ein automatisiertes Fahrzeug erfordert eine ganzheitliche Validierungsstrategie. Zur Entwicklung hochautomatisierter Fahrfunktionen sind innovative methodische Ansätze und Verfahren notwendig, mit denen die Sicherheitsrisiken beim Einsatz von Umgebungssensoren, hochleistungsfähigen Vernetzungsarchitekturen und KI-basierten Algorithmen für die Objekterkennung und Fahrplanung identifiziert und behandelt werden können. Hierzu ist eine durchgängige Betrachtung der Sicherheitsrisiken in den Entwicklungs- und Technologie-Phasen der Fahrzeugsysteme notwendig. Die Herstellung eines durchgängigen Zusammenhangs zwischen den identifizierten Sicherheitsrisiken, den

implementierten Sicherheitsmechanismen und angewendeten Prüfverfahren bildet die notwendige Argumentationsgrundlage für einen Nachweis der Funktionssicherheit. Im Verbundprojekt wurde durch TÜV NORD Mobilität eine Methodik zur durchgängigen und ganzheitlichen Betrachtung der Systemsicherheit am Anwendungsfall AutoConstruct konzeptionell erarbeitet und am AutoConstruct Anwendungsfall erprobt.

CMORE:

Wirtschaftliche Erfolgsaussichten

CMORE bewegt sich in einem sehr dynamischen Markt, bei dem jeder Stillstand sofort bestraft wird. Deshalb werden die Ergebnisse aus AutoConstruct bereits genutzt oder fließen umgehend in die Weiterentwicklung des Dienstleistungsangebotes ein.

Darüber hinaus werden Ergebnisse aus AutoConstruct zur Weiterentwicklung der CMORE-Software-Produkte verwendet, womit eine wesentlich größere Multiplikationswirkung erreicht werden kann.

Nach entsprechender Finalisierung sollen die im Rahmen von AutoConstruct entwickelten Tools zur langfristigen Nutzung in Kundenprojekten in die CMORE Toollandschaft integriert werden. Dabei ist vorgesehen, die Komplexität und der Umfang noch zu erweitern; z. B. um ein Modul für automatisierte Reporterstellung. Des Weiteren soll eine Schnittstelle zur Automatisierung, z. B. über Konsolenbefehle, geschaffen werden.

Wissenschaftliche und / oder technische Erfolgsaussichten

Die Arbeitsergebnisse des Projekts AutoConstruct haben maßgeblich zum internen Know-how-Aufbau beigetragen und konnten schon in mehreren weiterführenden Projekten genutzt werden.

Des Weiteren wird das im Rahmen von AutoConstruct erlangte Wissen in Verbindung mit der praktischen Umsetzung auch an Hochschulen und Universitäten transferiert. Dazu sollen zu unterschiedlichen Themenbereichen Studien-, Bachelor- und Masterarbeiten vergeben werden. Zum beidseitigen Nutzen wird so das wissenschaftliche Netzwerk erweitert.

Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Bereits vor Ende des Projektes hat CMORE, zusammen mit den Forschungspartnern, Ausschau nach geeigneten wissenschaftlichen Anschlussprojekten gehalten. Drei weitere Projekte befinden sich bereits in der Umsetzung. Da CMORE sich in einem sehr dynamischen Markt bewegt, wo neueste Forschungsergebnisse existentiell sind, wird sich CMORE gezielt auf die wirtschaftliche Weiterverfolgung der erarbeiteten Erkenntnisse konzentrieren.

2.4 Bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Fraunhofer:

In den letzten Jahren wurden im Bereich der kamerabasierten Objekterkennung vor allem große Fortschritte mit Neuronalen Netzen erzielt. In allen großen wissenschaftlichen Challenges führen Neuronale Netze den Stand der Technik an. Die größte Herausforderung bestand in den vergangenen Jahren beim Einsatz von Neuronalen Netzen im ADAS-Bereich in der effizienten Umsetzung auf geeigneter Hardware.

Dieser Herausforderung haben sich demzufolge viele große Hardwarehersteller, allen voran NVIDIA und Intel, angenommen und entsprechende Hardware wie den Drive PX2 [29] vorgestellt.

Die Kombination von effizienteren Architekturen von Neuronalen Netzen und Hardware ermöglicht deren breiten Einsatz im Perzeptionsbereich des autonomen Fahrens. Dies spiegelt sich auch im aktuellen Trend wider, der zeigt, dass große Technologieunternehmen, OEMs und Tiers der Automobilindustrie den Einsatz von Neuronalen Netzen stärker vorantreiben.

Den Autoren sind keine weiteren Fortschritte für die Erkennung von komplexen Verkehrszeichen von deutschen Baustellen bekannt.

Continental & CMORE:

Im Rahmen des Projektes wurden relevante Produkte sowie Projekte und Forschungsprojekte (soweit bekannt) recherchiert. (siehe auch Kapitel 1.4).

Neue Erkenntnisse in diesem Bereich von anderen Unternehmen / Forschungseinrichtungen sind dem Projekt Team auch während der Projektlaufzeit nicht bekannt geworden.

Auch weiterhin besteht ein großes Interesse an dem Thema Baustellenerkennung, jedoch ist derzeit kein weiteres Projekt zu dem Thema bekannt.

b-plus:

Automotive Ethernet Netzwerke etablierten sich während der Projektlaufzeit weiter als die Vernetzungstechnologie im Automotive Bereich. In Serienfahrzeugen befinden sich aktuell immer noch nur 100 Mbit/s Ethernet Netzwerke im Einsatz, wobei das im Projekt ebenfalls

verwendete Automotive 1 Gbit/s Ethernet in den nächsten Jahren auch in Serienprodukten zum Einsatz kommen wird. Automotive Ethernet Varianten mit Übertragungsgeschwindigkeiten zwischen 2,5 Gbit/s und 50 Gbit/s befinden sich aktuell in der Standardisierung bzw. soll die Standardisierung demnächst gestartet werden (für Übertragungsgeschwindigkeiten von 25 Gbit/s bis 50 Gbit/s). Die eingesetzten Plattformen (HIS-Switch und DecACe-Switch) liegen somit im Bereich der zukünftig zu erwartenden Übertragungsgeschwindigkeiten.

Eine weitere neue Kommunikationstechnologie, die sich in der Projektlaufzeit im Automotive Bereich ausgebreitet und im Projekt benutzt wurde, sind SerDes [30] Übertragungstrecken über Koaxialleitungen. Hierbei handelt es sich aber aktuell um mehr proprietäre Lösungen einzelner Halbleiterhersteller zu denen öffentlich nur sehr wenig Informationen verfügbar sind. Diese Technologie dient dabei nur zur Punkt-zu-Punkt Verbindung zwischen zwei Steuergeräten. Aktuell gibt es Initiativen eine standardisierte SerDes Lösung zu entwickeln. Diese Art von Kommunikationstechnologie wurde im Projekt auf der Strecke von Kamera zum Messtechnik Adapter eingesetzt.

Die im Projekt betrachtete Time-Sensitive Network (TSN) [31] Technologie hat sich während der Projektlaufzeit ebenfalls weiterentwickelt. TSN entwickelt sich immer mehr zur Basistechnologie für Echtzeitkommunikation, sowohl in Industrieanlagen im Mobilfunk und der Telekommunikation, sowie im Automobil. Es wurden während der Projektlaufzeit verschiedene Standardisierungsaktivitäten zur Erweiterung von TSN gestartet. Viele beschäftigen sich dabei mit der Konfiguration über NETCONF und YANG. Die entsprechenden Projekte starteten jedoch erst gegen Ende des Projektes AutoConstruct und konnten damit nicht mehr miteinbezogen werden.

TÜV NORD Mobilität:

Auf Grundlage der von TÜV NORD Mobilität entwickelten Arbeitsergebnisse wurden Erkenntnisse und Lösungsvorschläge abgeleitet und entsprechend der übergeordneten Ziele des Forschungsprogramms der Wirtschaft und Wissenschaft zugänglich gemacht. Weiterhin wurden Erkenntnisse in die industrielle Normung eingebracht. Diesbezüglich wurden während der Projektlaufzeit mehrere Vorträge auf Fachtagungen durchgeführt und Erkenntnisse in Form von Kommentierungen und Vorschlägen in Arbeitsgruppen zur Erarbeitung von neuen Vernetzungsstandards, Sicherheitsnormen und Fahrzeugtypgenehmigungsregelungen für die Automobilindustrie eingebracht. Zudem wurden die Erkenntnisse in der VdTÜV-BSI Arbeitsgruppe Künstliche Intelligenz vorgestellt.

Die durch TÜV NORD Mobilität im Verbundprojekt AutoConstruct identifizierten technologischen Sicherheits- und Vernetzungs-Anforderungen werden durch die regelmäßige Teilnahme in nationalen und internationalen Arbeitsgruppen eingebracht. Der Zeithorizont richtet sich dabei nach den Roadmaps der nachfolgend genannten Arbeitsgruppen:

- UN ECE Working Party on Automated/Autonomous and Connected Vehicles (GRVA) zur Entwicklung von Typgenehmigungsregelungen
- Normenausschuss Automobil NA 052-00-32-08-06 AK „Safety of the intended Functionality“ zur Standardisierung der ISO 21448 [32]
- Normenausschuss Automobil NA 052-00-32-11 AK „Cybersecurity“ zur Standardisierung der ISO/SAE 21434 [33]
- Normenausschuss Automobil NA 052-00-31-03 AK "Datenbusse und Protokolle“ zur Standardisierung der ISO 21111
- OPEN Alliance (One-Pair Ethernet) SIG zur Entwicklung von Anforderungs- und Testspezifikationen für In-Vehicle Ethernet
- BSI-VdTÜV Arbeitskreis Künstliche Intelligenz
- DIN Arbeitsgruppen zur Normungsroadmap Künstliche Intelligenz

2.5 Veröffentlichungen des Ergebnisses

TÜV NORD Mobilität:

- Vortrag „Herausforderungen an eine sichere Umfelderkennung für das automatisierte Fahren“ 22. SafeTRANS [34] Industrial Day, Mai 2017 in Bremen
- Vortrag „Challenges for a dependable environment detection for automated driving functions“ ADFD Symposium on Automated Driving, Future Mobility and Digitalization [35] 2017, September 2017 in Hannover
- Vortrag „Requirements for switched automotive Ethernet networks for camera based environment detection“ Bordnetz Kongress [36] September 2017 in Landshut
- Vortrag “Challenges for a dependable environment detection for automated driving functions“ Sino-German Symposium “Optimization and Control of Smart Cars in IoT”, Dezember 2017 in Shanghai
- Ausstellung und Präsentation des AutoConstruct Fzg-Prototyps TÜV Nord Mobilität (TNM) Führungskräfteetagung, Januar 2018 in Hannover
- Ausstellung und Präsentation des AutoConstruct Versuchsträgers 150 Jahre TÜV NORD Festival am 9. Mai 2019 im Hamburg

- Vorstellung und Diskussion Projektergebnisse (Schwerpunkt: Safety-Anforderungen und Validierungsansätze KI-basierte Umfelderkennung) Beiratssitzung TNM IFM am 14. Juni 2019 bei Continental in Frankfurt
- Vorstellung Projekt AutoConstruct BSI-VdTÜV AG Künstliche Intelligenz am 5.11.2019

b-plus:

Ausstellung des AutoConstruct Autos auf der Automotive Testing Expo [37] in Stuttgart vom 05.06.2018 – 07.06.2018

Fraunhofer:

Teilergebnisse wurden unter „Automatische Erkennung von Verkehrslenkungstafeln im Baustellenbereich“ auf der Tagung Automatisiertes Fahren am 21. November 2019 von Fraunhofer IAIS vorgestellt.

Es besteht die Möglichkeit zur Veröffentlichung der trainierten Modelle über die Plattform des EU-Projekts AI4EU. Die zum Training verwendeten Daten bleiben dadurch geschützt.

Continental:

Seitens Continental gab und gibt es keine geplanten Veröffentlichungen/Artikel o. Ä. aus dem Projekt AutoConstruct.

CMORE:

Generell wurden Zwischenergebnisse regelmäßig so aufbereitet, dass diese interessierten Dritten präsentiert werden können.

Literaturverzeichnis

- [1 A. Wimmer, Dissertation: Umfelderkennung und -modellierung von Baustellen für Fahrerassistenzsysteme, Ulm: Universität Ulm. Fakultät für Ingenieurwissenschaften und Informatik, 2014.
- [2 MobilEye, „MobilEye,“ 12 Mai 2020. [Online]. Available: <https://www.mobileye.com/our-technology/adas/>.
- [3 Bosch, „Bosch Mobility Solutions,“ 12 Mai 2020. [Online]. Available: <https://www.bosch-mobility-solutions.com/en/products-and-services/passenger-cars-and-light-commercial-vehicles/driver-assistance-systems/lane-departure-warning/multi-purpose-camera/>.
- [4 Continental, „Continental ADAS,“ 12 Mai 2020. [Online]. Available: <https://www.continental-automotive.com/de-DE/Passenger-Cars/Autonomous-Mobility/Enablers/Cameras>.
- [5 Bosch, „Youtube - DE | Bosch Baustellenassistent - MPK 2013,“ 26 Juni 2013. [Online]. Available: https://www.youtube.com/watch?v=1jlb5MOU6_0. [Zugriff am 13 Mai 2020].
- [6 D. I. Ferguson und D. J. Brunette, „Mapping active and inactive construction zones for autonomous driving“. United States Patent US9141107B2, 2013.
- [7 „wikipedia.org,“ 25 02 2020. [Online]. Available: https://de.wikipedia.org/wiki/Transmission_Control_Protocol/Internet_Protocol. [Zugriff am 06 2020].
- [8 „wikipedia.org,“ 27 11 2017. [Online]. Available: [https://de.wikipedia.org/wiki/Scalable_Service-Oriented_Middleware_over_IP#:~:text=Scalable%20Service%2DOriented%20Middleware%20over%20IP%20\(SOME%2FIP\),der%20neuen%20%22Foundation%22%20ver%C3%B6ffentlicht..](https://de.wikipedia.org/wiki/Scalable_Service-Oriented_Middleware_over_IP#:~:text=Scalable%20Service%2DOriented%20Middleware%20over%20IP%20(SOME%2FIP),der%20neuen%20%22Foundation%22%20ver%C3%B6ffentlicht..) [Zugriff am 06 2020].
- [9 „wikipedia.org,“ 20 03 2020. [Online]. Available: [https://de.wikipedia.org/wiki/AUTOSAR#:~:text=AUTOSAR%20\(AUTomotive%20Open%20System%20Architecture,%2D%2C%20Halbleiter%2D%20und%20Softwareindustrie..](https://de.wikipedia.org/wiki/AUTOSAR#:~:text=AUTOSAR%20(AUTomotive%20Open%20System%20Architecture,%2D%2C%20Halbleiter%2D%20und%20Softwareindustrie..) [Zugriff am 06 2020].
- [1 M. Namysl und I. Konya, „Efficient, Lexicon-Free OCR using Deep Learning,“ *arXiv:1906.01969v1*, 05 06 2019.
- [1 S. Eickeler, M. Valdenegro, T. Werner und M. Kieninger, „Future Computer Vision Algorithms for Traffic Sign Recognition Systems,“ *Advanced Microsystems for Automotive Applications 2015*, pp. 69 - 77, 2015.
- [1 L. Pink und S. Eickeler, „Performance Enhancements for the Detection of Rectangular Traffic Signs,“ *Advanced Microsystems for Automotive Applications 2016*, pp. 113-123, 2016.
- [1 J.-P. He und Y. Ma, „Triangle detection based on windowed Hough Transform,“ in *International Conference on Wavelet Analysis and Pattern Recognition*, Baoding, 2009.

- [1 S. Mori, H. Nishida und H. Yamada, Optical Character Recognition, USA: John Wiley & Sons, Inc., 4] 1999.
- [1 Y. Lecun, L. Bottou, Y. Bengio und P. Haffner, „Gradient-based learning applied to document 5] recognition,“ *Proceedings of the IEEE*, pp. 2278-2324, 1998.
- [1 D. P. Kingma und B. Jimmy, „Adam: A Method for Stochastic Optimization,“ *arXiv:1412.6980*, 6] 2017.
- [1 J. Redmon und A. Farhadi, „YOLOv3: An Incremental Improvement,“ *CoRR*, 2018. 7]
- [1 A. Geiger, P. Lenz und R. Urtasun, „Vision meets Robotics: The KITTI Dataset,“ *International 8] Journal of Robotics Research (IJRR)*, 2013.
- [1 M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Benenson, U. Franke, S. Roth und B. 9] Schiele, „The Cityscapes Dataset for Semantic Urban Scene Understanding,“ *IEEE Conference on Computer Vision and Pattern Recognition*, 2020.
- [2 P. Viola und M. Jones, „Rapid Object Detection using a Boosted Cascade of Simple Features,“ 0] *Conference on Computer Vision and Pattern Recognition*, 2001.
- [2 Y. Deng, B. S. Manjunath und H. Shin, „Color image segmentation,“ in *Proceedings. 1999 IEEE 1] Computer Society Conference on Computer Vision and Pattern Recognition*, Fort Collins, CO, USA, 1999.
- [2 A. Koschan und M. Abidi, „Detection and classification of edges in color images,“ *IEEE Signal 2] Processing Magazine*, pp. 64-73, Januar 2005.
- [2 J. Redmon und A. Farhadi, „YOLOv3: An Incremental Improvement,“ *arXiv*, 2018. 3]
- [2 A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto und H. 4] Adam, „MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,“ *CoRR*, 2017.
- [2 T.-Y. Lin, P. Goyal, R. B. Girshick, K. He und P. Doll, „Focal Loss for Dense Object Detection,“ *CoRR*, 5] Nr. DBLP:journals/corr/abs-1708-02002, 2017.
- [2 D. A. D. E. C. S. S. R. C.-Y. F. A. C. B. Wei Liu, „SSD: Single Shot MultiBox Detector,“ in *Leibe B., 6] Matas J., Sebe N., Welling M. (eds) Computer Vision – ECCV 2016*, 2016.
- [2 J. Huang, V. Rathod, C. Sun, M. Zhu, A. Korattikara, A. Fathi, I. Fischer, Z. Wojna, Y. Song, S. 7] Guadarrama und K. Murphy, „Speed/Accuracy Trade-Offs for Modern Convolutional Object Detectors,“ in *Conference on Computer Vision and Pattern Recognition CVPR*, Honolulu, HI, USA, 2017.
- [2 I. Döbel, M. Leis, M. M. Vogelsang, D. Neustroev, H. Petzka, A. Riemer, S. Rüping, A. Voss, M. 8] Wegele und J. Welz, „Maschinelles Lernen: Eine Analyse zu Kompetenzen Forschung und Anwendung,“ *Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V.*, München, 2018.

- [2 NVIDIA, „www.mobilegeeks.de,“ NVIDIA, 2016. [Online]. Available:
9] <https://www.mobilegeeks.de/artikel/nvidia-drive-px-2/>. [Zugriff am 08 06 2020].
- [3 „de.wikipedia.org,“ 13 05 2019. [Online]. Available: <https://de.wikipedia.org/wiki/SerDes>. [Zugriff
0] am 06 2020].
- [3 „de.wikipedia.org,“ 02 04 2020. [Online]. Available: [https://de.wikipedia.org/wiki/Time-
1\] Sensitive_Networking](https://de.wikipedia.org/wiki/Time-1_Sensitive_Networking). [Zugriff am 06 2020].
- [3 „de.wikipedia.org,“ 22 05 2020. [Online]. Available: <https://de.wikipedia.org/wiki/SOTIF>. [Zugriff
2] am 06 2020].
- [3 „de.wikipedia.org,“ 06 03 2020. [Online]. Available:
3] https://de.wikipedia.org/wiki/ISO/SAE_21434. [Zugriff am 06 2020].
- [3 „www.safetrans-de.org,“ [Online]. Available: [https://www.safetrans-
4\] de.org/de/Veranstaltungen/2017/05/18/22.-safetrans-industrial-day??pid=1](https://www.safetrans-4] de.org/de/Veranstaltungen/2017/05/18/22.-safetrans-industrial-day??pid=1). [Zugriff am 06
2020].
- [3 „euroforum,“ [Online]. Available: <https://www.euroforum.de/adfd/>. [Zugriff am 06 2020].
5]
- [3 „bordnetze,“ [Online]. Available: <https://www.bordnetze.eu/>. [Zugriff am 06 2020].
6]
- [3 „testing-expo,“ [Online]. Available: [https://www.testing-expo.com/europe/de/reviews-
7\] videos.php?year=2018](https://www.testing-expo.com/europe/de/reviews-7] videos.php?year=2018). [Zugriff am 06 2020].
- [3 „CleanThinking,“ 27 Mai 2020. [Online]. Available: [https://www.cleantesting.de/autonomes-
8\] fahren-fuenf-level-bis-zum-selbstfahrenden-auto/](https://www.cleantesting.de/autonomes-8] fahren-fuenf-level-bis-zum-selbstfahrenden-auto/).

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht Konsortium
3. Titel AutoConstruct – Echtzeitfähige Umfelderkennung von Baustellen mittels serientauglicher und kostenoptimierter Kamera-Sensorik für das hoch- und vollautomatisierte Fahren	
4. Autor(en) [Name(n), Vorname(n)] ADC Automotive Distance Control Systems GmbH CMORE Automotive GmbH b-plus GmbH TÜV-Nord Mobilität GmbH & Co. KG Frauenhofer-Gesellschaft zur Förderung der angewandten Forschung e. V.	5. Abschlussdatum des Vorhabens November 2019
	6. Veröffentlichungsdatum
	7. Form der Publikation Dokument
8. Durchführende Institution(en) (Name, Adresse) ADC Automotive Distance Control Systems GmbH CMORE Automotive GmbH b-plus GmbH TÜV-Nord Mobilität GmbH & Co. KG Frauenhofer-Gesellschaft zur Förderung der angewandten Forschung e. V.	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19A16011
	11. Seitenzahl 129
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Energie 11019 Berlin	13. Literaturangaben 38
	14. Tabellen 6
	15. Abbildungen 85
16. Zusätzliche Angaben	
17. Vorgelegt bei (Titel, Ort, Datum)	
18. Kurzfassung Im Projekt AutoConstruct wurde unter Verwendung serientauglicher und kostenoptimierter Sensorik (Kamera) eine integrierte Anwendung zur echtzeitfähigen Umfelderkennung von Baustellen für das hoch- und vollautomatisierte Fahren entwickelt und erprobt. Dazu wurden zum einen innovative Methoden zur Sensordatenanalyse erforscht und echtzeitfähige Algorithmen zur Erkennung von komplexen Baustellenschildern, -begrenzungen (z. B. Baken) sowie für die robuste und präzise Erkennung von überlagerten Fahrbahnmarkierungen realisiert. Zum anderen wurden die Algorithmen in eine hoch performante und sichere Fahrzeug IT-Umgebung integriert, die es ermöglichte, in Echtzeit große Datenmengen zeitsynchron zu verarbeiten, aufzuzeichnen und durch algorithmenbasierte Labelingverfahren zu annotieren. Hierzu wurden breitbandige Kommunikationssysteme in einer emissionsreichen Umgebung (Fahrzeug) integriert und für hochautomatisiertes Fahren benötigte Vernetzungsanforderung erprobt und optimiert.	
19. Schlagwörter Fahrerassistenz, Umfelderkennung, Baustellenerkennung, Baustellen, Fahrspurerkennung, Begrenzungsobjekterkennung, Baustellen Hinweisschilder, Fahrtrichtungsweiser, Baustellen-Ankündigungs-Verkehrszeichen, Semantische Segmentierung, RetinaNet, Neuronale Netze	
20. Verlag	21. Preis kostenlos

Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Final report
3. title AutoConstruct – Real-time environment detection of construction sites using series-compatible and cost-optimized camera sensors for highly and fully automated driving	
4. author(s) (family name, first name(s)) ADC Automotive Distance Control Systems GmbH CMORE Automotive GmbH b-plus GmbH TÜV-Nord Mobilität GmbH & Co. KG Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e. V.	5. end of project November 2019
	6. publication date
	7. form of publication Document
8. performing organization(s) (name, address) ADC Automotive Distance Control Systems GmbH CMORE Automotive GmbH b-plus GmbH TÜV-Nord Mobilität GmbH & Co. KG Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e. V.	9. originator's report no.
	10. reference no. 19A16011
	11. no. of pages 129
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Energie/ Federal Ministry for Economic Affairs and Energy 11019 Berlin	13. no. of references 38
	14. no. of tables 6
	15. no. of figures 85
16. supplementary notes	
17. presented at (title, place, date)	
18. abstract In the AutoConstruct project, an integrated application for real-time environment detection of construction sites for highly and fully automated driving was developed and tested using series-compatible and cost-optimized sensors (cameras). On the one hand, innovative methods for sensor data analysis were researched and real-time algorithms for the recognition of complex site signs, boundaries (e.g. beacons) as well as for the robust and precise detection of superimposed road markings. On the other hand, the algorithms were integrated into a high-performance and secure vehicle IT environment, which made it possible to process large amounts of data in real time, record them and annotate them using algorithm-based labeling processes. Broadband communication systems were integrated in an emission-rich environment (vehicle) and the networking requirements required for highly automated driving were tested and optimized.	
19. keywords Driver assistance, environment detection, construction site detection, lane detection, boundary object detection, construction site signs, direction indicators, construction site announcement traffic signs	
20. publisher	21. price free