

Partnerspezifischer Schlussbericht

Berichtszeitraum: 01.01.2021 - 31.03.2024

Valeo Schalter und Sensoren GmbH

Vorhabenbezeichnung KI Wissen - Entwicklung von Methoden für
die Einbindung von Wissen in
maschinelles Lernen

Laufzeit **des** 01.01.2021-31.03.2024
Vorhabens

Förderkennzeichen 19A20020P

Fälligkeitsdatum 01.10.2024

Erstellungsdatum 12.06.2024



Dokumenteninformation

Autoren

Dr. Christian Müller-Hirschhorn - Valeo Schalter und Sensoren GmbH

Jonas Pfisterer - Valeo Schalter und Sensoren GmbH

Peerayut Khongsab - Valeo Schalter und Sensoren GmbH

Matthias Reuse - Valeo Schalter und Sensoren GmbH

Dr. Vera Stehr - Valeo Schalter und Sensoren GmbH

Tobias Wagner - Valeo Schalter und Sensoren GmbH

Toni Baric - Valeo Schalter und Sensoren GmbH

Dr. Johannes Link - Valeo Schalter und Sensoren GmbH

Reviewer

Dr. Alexander Nagel - Valeo Schalter und Sensoren GmbH

Dr. Christian Müller-Hirschhorn - Valeo Schalter und Sensoren GmbH

Kontakt

Dr. Christian Müller-Hirschhorn

Valeo Schalter und Sensoren GmbH

Hummendorfer Str. 74

D-96317 Kronach

Deutschland

Phone: +49 (0) 176 3000-4550

Email: christian.mueller-hirschhorn@valeo.com

Revisionslog

Version	Datum	Kommentar	Autor	Partner
1.0	20.06.2024	initialer Entwurf	Dr. Johannes Link	Valeo Schalter und Sensoren GmbH
1.0	24.07.2024	Endfassung	Dr. Alexander Nagel	Valeo Schalter und Sensoren GmbH

Inhaltsverzeichnis

1	Zusammenfassung	12
2	Übersicht.....	14
2.1	Aufgabenstellung	14
1.	Inhaltliche Schwerpunkte des Partners Valeo	15
2.2	Voraussetzungen für das Vorhaben	16
2.	Operative Projektsteuerung	17
3.	Ergebnisverbreitung	17
4.	Projektorganisation.....	17
2.3	Planung und Ablauf.....	18
2.3.1	Projektstruktur	18
2.3.2	Zeitlicher Ablauf	21
2.3.3	Deliverables und Meilensteine.....	23
2.4	Stand der Wissenschaft und Technik	26
5.	Ansätze und Grundbausteine der KI-Forschung	26
6.	Offene Fragestellungen und Fortschritt gegenüber dem Stand der Technik	38
7.	Neuheit im Vergleich zu laufenden Aktivitäten	40
8.	Bezug zu aktuellen Forschungsprojekten.....	42
2.5	Zusammenarbeit mit anderen Stellen	47
9.	EICT	47
10.	Capgemini Outsourcing.....	48
3	Eingehende Darstellung	49
3.1	Erzielte Ergebnisse	49
3.1.1	TP1: Wissensintegration	49
3.1.2	TP2: Wissensextraktion.....	80
3.1.3	TP3: Wissenskonformität.....	94
3.1.4	TP4: Enabler, Integration und Demonstration	112
3.1.5	TP5: Projektmanagement und Ergebnisverbreitung.....	149
3.2	Zahlenmäßiger Nachweis	153
3.3	Notwendigkeit der Förderung.....	154
3.4	Nutzen und Verwertbarkeit	155
3.5	Veröffentlichungen.....	155

3.5.1	Erfolgte Veröffentlichungen	155
3.5.2	Geplante Veröffentlichungen.....	158
4	Literaturverzeichnis	159

Abbildungsverzeichnis

Abbildung 1: KI Wissen: Kombination von daten- und regelbasierten Verfahren	14
Abbildung 2: Projektorganisation	17
Abbildung 3: Gesamtansatz von KI Wissen.....	20
Abbildung 4: Projektierungsansatz, inklusive Verantwortlichkeiten der Teilprojekte	21
Abbildung 5: Ursprüngliche Planung der Inkrementellen Projektdurchführung ohne kostenneutrale Verlängerung. Der detaillierte Zeitplan mit kostenneutraler Verlängerung ist in Abbildung 6 dargestellt.....	22
Abbildung 6: Zeitlicher Ablauf der TP's und AP's inklusive kostenneutraler Verlängerung.	23
Abbildung 7: Beteiligung der Konsortialpartner an den identifizierten Forschungsvorhaben mit inhaltlichem Bezug zu KI Wissen	42
Abbildung 8: : Schematische Architektur des PointPillars-Netzwerks zur 3D-Objekterkennung auf Punktwolken [1]	50
Abbildung 9: : Horizontal ist die Nummer aller von PointPilars prädizierten Boxen vom Kitti validation split aufgetragen. Vertikal sind die Werte der genormten Chamfer-Distanz und der IoU (Abkürzung für "Intersection over Union") aufgetragen.	52
Abbildung 10: Schematische Darstellung des AGO-Net Ansatzes, um Objektmodelle als a-priori Wissen zu verwenden. Ein konzeptueller Objektdetektor wird verwendet, um das Wissen während des Trainings auf die perzeptuellen Beispiele zu übertragen [aus AGO-Net Publikation]	53
Abbildung 11: Eine Skizze für alle acht Ground Truth Sampling Variationen ist dargestellt. Der LiDAR-Sensor ist als schwarzes Quadrat dargestellt. Kästchen und Punkte beziehen sich auf ein exemplarisches Objekt, das alle acht Varianten umfasst. Die Linien innerhalb der Kästchen zeigen die Ausrichtung an. Die Farben der Kästchen stehen für die Positionsvariante, die Farben der mittleren Linien die Orientierungsvariante. Der gestrichelte Kreis zeigt den polaren Abstand der Ground Truth Position.	55
Abbildung 12: Eine Skizze für alle acht Ground Truth Sampling Variationen ist dargestellt. Der LiDAR-Sensor ist als schwarzes Quadrat dargestellt. Die Boxen und Punkte beziehen sich auf ein exemplarisches Objekt, das alle acht Varianten umfasst. Die Linien innerhalb der Boxen zeigen die Ausrichtung an. Die Farben der Boxen stehen für die Variante der Positionierung, die Farben der mittleren Linien die Variante der Orientierung. Der gestrichelte Kreis zeigt den polaren Abstand der Ground Truth Position.	56
Abbildung 13: Die mean average precision (Auto und Fußgänger) auf den verschiedenen Größen der Trainingsplits für PointPillars ohne (rot) und mit (blau) GT-Sampling. Die Unterschiede in den Medianen zwischen ohne und mit GT-Sampling für jede Datensatzgröße werden in der unteren linken Ecke angezeigt. Am besten zu sehen bei Vergrößerung und in Farbe.....	58
Abbildung 14: Die mean average precision (Auto und Fußgänger) auf den verschiedenen Größen der Trainingsplits für CenterPointohne (rot) und mit (blau) GT-Sampling. Die Unterschiede in den Medianen zwischen ohne und mit GT-Sampling für jede Datensatzgröße werden in der unteren linken Ecke angezeigt. Am besten zu sehen bei Vergrößerung und in Farbe.....	58
Abbildung 15: Design Pattern der dargestellten Methode nach Bekkum et al.. Das a-priori Wissen ist in grün markiert	59

Abbildung 16: Punktwolken eines Lidar-Sensors (Scala Generation 2 von Valeo) in Vogelperspektive vor (linkes Bild) und nach (rechtes Bild) Verstellen der Optik. Die Punkte sind je nach Empfangsdiode farblich markiert	60
Abbildung 17: 3D-Darstellung einer Punktwolke als Eingabe für das PointNet	61
Abbildung 18: Schematische Darstellung des Sichtfeldes eines LiDAR-Sensors bestehend aus Sende- und Empfangsbereich. Links ist der Normalfall gezeigt. In der rechten Zeichnung sind Sender und Empfänger relativ zueinander verstellt.....	63
Abbildung 19: Das Sichtfeld eines idealen LiDAR-Sensors ist links gezeigt. Das rechte Bild entspricht einem LiDAR-Sensor mit verstellter Optik.	64
Abbildung 20: Der Eingang einer Waschstraße wird fälschlicherweise als Person mit einer Konfidenz von 0.38 erkannt.	64
Abbildung 21: Aufnahmen einer Kamera in einem Parkhaus mit dynamischen Objekten auf dem linken Bild und ohne auf dem rechten.	65
Abbildung 22: Die Architektur unserer wissensbasierten Objekterkennung YOLACT 2. Das statische und das zu prozessierende Bild durchlaufen denselben Hauptstrang mit denselben Netzparametern (Zeichnung übernommen und angepasst aus [2]).	66
Abbildung 23: : (links) Bild einer statisch an der Wand montierten Kamera zur Detektion von Fußgängern und Fahrzeugen. (rechts) Gleiche Kameraperspektive, diesmal jedoch ohne zu detektierende Objekte.	67
Abbildung 24: "Background Aware Shared Resnet" (BASR). Das statische und das aktuelle Kamerabild laufen durch denselben Hauptstrang. (Zeichnung angepasst aus .)	68
Abbildung 25: "Background Aware Individual Resnet" (BAIR). Das statische und das aktuelle Kamerabild durchlaufen separate Hauptstränge. (Zeichnung angepasst aus 4.).....	68
Abbildung 26: Relevanz in Abhängigkeit der Sensitivität. Zum Vergleich ist außer der Klasse "Fußgänger" auch die Kurve der Klasse "Fahrzeug" dargestellt. Die gestrichelten Linien kennzeichnen verschiedene Konfidenzschwellen zur Berechnung (0,8; 0,6; 0,4; 0,2).	70
Abbildung 27: Entwurfsmuster für das entwickelte hybride neuronale Netz.	71
Abbildung 28: : Methodik (links) und Ergebnisse (rechts) des entwickelten Netzes.	72
Abbildung 29: Gaussian Mixture Models für Personenkraftwagen extrahiert aus dem nuScenes Datensatz mit einem relativen Sensorwinkel von $-\pi/2$ (Automobil von hinten) auf dem linken Bild und einem relativen Sensorwinkel von $\pi/4$ (Automobil von der Seite) auf dem rechten Bild.	74
Abbildung 30: <i>Gerenderte dichte Punktwolke eines CAD Modell aus dem ShapeNet Datensatz. Das linke Bild zeigt die Vogelperspektive, das rechte Bild die Seitenansicht.</i>	74
Abbildung 31: Ausschnitt aus einer Punktwolke aus dem NuScenes Datensatz . Weiße Punkte gehören zur ursprünglichen Punktwolke. Blaue Boxen markieren die Objekte. Lila Punkte wurden aus der konzeptionellen Datenbasis in die Punktwolke eingefügt.	75
Abbildung 32: (links oben) Ein "leeres" Bild, mit dessen Hilfe in einem anderen Bild ein Fußgänger detektiert werden soll. (links unten) Das gleiche Bild, jedoch mit zufälligen Abweichungen in Helligkeit, Kontrast, Sättigung und Farbwert. In der zweiten Spalte wurden die Bilder aus der ersten Spalte normiert (alle drei Farbkanäle separat), in der dritten Spalte in Graustufen umgewandelt und in der vierten Spalte die Graustufenbilder normiert.	79

Abbildung 33: Die optimale Distanzmessung mit einem Nahfeld-Lidar-Sensor (linkes Bild) weist im Falle von Überbelichtung einen Bereich mit falschen Detektionen auf (mittleres Bild). Der logarithmische Fehler zeigt klar den problematischen Bereich in der Bildmitte (rechtes Bild) ...	81
Abbildung 34: Architektur zur Erstellung einer realistischen HD-Karte.	83
Abbildung 35: Toolchain für die Simulationserstellung.	84
Abbildung 36: Tachymetermessungen und Simulationsumgebung in dSPACE Motion Desk.	84
Abbildung 37: LeGO-LOAM SLAM der Valeo-Anlagen und Bild der Valeo-Anlagen in Kronach.	85
Abbildung 38: Implementierung einer simulierten Fischaugenkamera in dSPACE Motiondesk (linkes Bild), Ausgabe dieser Fischaugenkamera (Bild in der Mitte) und Aufnahme der entsprechenden realen Kamera (rechtes Bild).....	85
Abbildung 39: Toolchain für die Simulationsgenerierung.....	86
Abbildung 40: Umgebungsmessungen und Simulationsumgebung in Unreal Engine 4.	86
Abbildung 41: Kamera-Lidar Sensor Fusion	87
Abbildung 42: Architektur für die Synchronisierung von Sensordaten basierend auf Zeitstempel Informationen.....	87
Abbildung 43: Extrinsische Kalibrierung von Lidar und Kamera, projizierte Punkte auf das Bild .	88
Abbildung 44: Fischaugenkamera Bildausgabe: (links) in Blender auf globaler farbiger Punktwolke(mitte) in CARLA Simulator mit manuell erstelltem Umgebungsmodell (rechts) der realen Kamera	88
Abbildung 45: Toolchain für die Simulationsgenerierung.....	89
Abbildung 46: Scannen der Kronach Teststrecke mit Leica Scanner. Punktwolke visualisiert in Cloud Compare	89
Abbildung 47: Erstellen einer 3D-Umgebung in Autodesk Revit	90
Abbildung 48: Bildausrichtung in Reality Capture und daraus resultierende dünne Punktwolken und Netzerstellung.....	90
Abbildung 49: 3D-texturierte Umgebung, erstellt mittels Photogrammetrie.....	90
Abbildung 50: Aufbau des Fisheye-Kamera-Sensors in der Valeo Kronach Teststrecke	91
Abbildung 51: Fischaugenkamera Nummer 5 Bildausgabe. (links) in Blender auf Photogrammetrie 3D Model (mitte) in dSpace Aurelion (rechts) der realen Kamera	91
Abbildung 52: Fischaugenkamera Nummer 0 Bildausgabe. (links) in Blender auf Photogrammetrie 3D Model (mitte) in dSpace Aurelion (rechts) der realen Kamera	91
Abbildung 53: Fischaugenkamera Nummer 0 Bildausgabe: (links) in Blender auf Laserscanner-Punktwolke (rechts) in CARLA Simulator	91
Abbildung 54: Valeo-Testfahrzeug, importiert in die CARLA Unreal Engine	92
Abbildung 55: Erstellen eines physischen Assets des Fahrzeugs in Blender.....	92
Abbildung 56: Erstellen eines physischen Assets und Blueprint des Fahrzeugs in Unreal Engine ..	93
Abbildung 57: Erstellen von Materialien aus Texturen in der Unreal Engine	93

Abbildung 58: Vergleich einer detektierten Person (unten) mit demselben Ausschnitt im statischen Bild (oben). Das Bild mit der Person wurde zusätzlich photometrisch verfremdet (Helligkeit, Kontrast, Sättigung, Farbton). Spalten von links nach rechts: Farbbild, Farbbild normiert, graukonvertiert, graukonvertiert normiert.	97
Abbildung 59: Statistische Auswertung von jeweils 1000 Bildpaaren, von denen das zweite Bild zufällig variierte photometrische Parameter (Helligkeit, Kontrast, Sättigung, Farbton) aufweist. Berechnet wurden jeweils Mittelwert, Standardabweichung, Minimum und Maximum des SSIM. Es wurde sowohl die detektierte Person mit demselben Ausschnitt im statischen Bild verglichen, als auch die Person bzw. der leere Bereich mit sich selbst.	98
Abbildung 60: Problematische Szenarien, bei denen Autos oder Fußgänger ungenau oder gar nicht erkannt werden. Die oberen Bilder zeigen eine Variation der Größe der Fußgänger. Die unteren Bilder zeigen eine Variation der Farbe der Fahrzeuge.....	101
Abbildung 61: Szene Frontansicht - Auto mit blauer Farbe - Erkennung 93 %, Auto mit grüner Farbe - Erkennung Konfidenz 79 %.....	102
Abbildung 62: Szene Frontansicht - Detektionskonfidenzen für erkannte Fahrzeugobjekte	102
Abbildung 63: Szene Heckansicht - Auto mit blauer Farbe - Erkennung 90 %, Auto mit grüner Farbe - Erkennung Konfidenz 47 %.....	103
Abbildung 64: Szene Heckansicht - Detektionskonfidenzen für erkannte Fahrzeugobjekte unterschiedlicher Farbe für die Fisheye-Kamera.	103
Abbildung 65: Szene Frontansicht: Lila-farbenes Auto - Erkennungskonfidenz 81%, Rotes Auto - Erkennungskonfidenz 90%	104
Abbildung 66: Balkendiagramm mit 96 RGB-Wertevariationen für Fischaugenkamera Nummer 0	104
Abbildung 67: Szene Frontansicht: Schwarzes Auto - Erkennungsgüte 94%, Grünes Auto - Erkennungsgüte 46%.	105
Abbildung 68: Balkendiagramm mit 96 RGB-Wertevariationen für Fischaugenkamera Nummer 5.	106
Abbildung 69: VW Passat importiert in CARLA Unreal Engine mit verschiedenen Texturen (braun-grün, orange, blau, rot)	107
Abbildung 70: Ändern der Farben der tga-Texturdatei: von der Standardfarbe grün-braun zu rot.	107
Abbildung 71: Auto mit grüner Farbe - Erkennung 80 %, Auto mit blauer Farbe - Erkennung Konfidenz 92 %.....	108
Abbildung 72: Liste der erkannten Autoobjekte und zugehöriges Balkendiagramm mit RGB-Werten für die Fisheye-Kamera 0 für 96 RGB-Wert-Variationen.	108
Abbildung 73: Auto mit schwarzer Farbe - Erkennung 93 %, Auto mit grüner Farbe - Erkennung Konfidenz 57 %.....	108
Abbildung 74: Liste der erkannten Autoobjekte und zugehöriges Balkendiagramm mit RGB-Werten für die Fisheye-Kamera 5 für 96 RGB-Wert-Variationen.	109
Abbildung 75: Simulierter Einparkvorgang im Automated-Valet-Parking für Use Case 1.5.	113
Abbildung 76: Use Case 1.6 zum autonomen Einparken mit statischen Sensoren.	114

Abbildung 77: Ego-Fahrzeug folgt der Fahrspur in der Standard-Stadt von CARLA und auf einer benutzerdefinierten Straße.	122
Abbildung 78: Ego-Fahrzeug mit Spurhaltassistent in Demoumgebung und in der CARLA-Stadt 04.	122
Abbildung 79: Ego-Fahrzeug überholt Pkw.	123
Abbildung 80: Ego-Fahrzeug bremst aufgrund von Annäherung an den Fußgänger.	123
Abbildung 81: Valeo Anwendungsfall Use Case 1.6.....	123
Abbildung 82: Valeo Teststrecke Erstellung in Roadrunner und Visualisierung der geöffneten Laufwerksdatei in OpenDrive Viewer.....	124
Abbildung 83: Szenario - Fahrzeug folgt den Wegpunkten, Fußgänger geht auf festgelegter Route.	124
Abbildung 84: Fischaugenkamera Bildausgaben für laufendes Szenario.....	124
Abbildung 85: Bild des Testfahrzeugs von Valeo mit diversen Kamera-, LiDAR-, Radar-, Ultraschall-Sensoren und einer inertialen Messeinheit.	126
Abbildung 86: Spezifikation der Sensoren im Valeo Aufnahmefahrzeug.	127
Abbildung 87: Ordnerstruktur für den Austausch von Messdaten.	128
Abbildung 88: Bild aus einer Sequenz für den Use Case 2: "komplexer Spurwechsel".....	130
Abbildung 89: Oben sieht man hier die Ausschnitte, die aus der OpenSTREETMAP heruntergeladen worden sind. Unten ist die Visualisierung der OpenDRIVE Karte in der SUMO GUI abgebildet...	136
Abbildung 90: Parkplatz des Standorts Kronach in Blender.	137
Abbildung 91: 3D-Modell der Gebäude am Valeo Standort in Kronach im Unreal Editor.....	138
Abbildung 92: Simuliertes Fisheye-Bild in CARLA.....	139
Abbildung 93: Das Kamerareferenzbild und die Bildebene.....	140
Abbildung 94: Fisheye-Bild des Valeo-Büros in Kronach.	141
Abbildung 95: CARLA-Kommunikationspipeline	141
Abbildung 96: Fisheye-Bild von CARLA des 3D-Modells des Valeo-Büros in Kronach.....	141
Abbildung 97: Workflow-Diagramm der Wissensextraktion.	142
Abbildung 98: Abbildung der Pixel des Cubemap-Bildes auf das Fisheye-Bild.....	143
Abbildung 99: Koordinatensystem für eine Cubemap nach Alan Watt.....	144
Abbildung 100: Entsprechende Cubemap zur Abbildung 99.	144
Abbildung 101: RGB-, Tiefen- und semantische Fischaugenbilder.	145
Abbildung 102: Fisheye-Bild mit der Standard-Nachbearbeitung von CARLA (links) und Fisheye-Bild mit der modifizierten Nachbearbeitung (rechts).....	148
Abbildung 103: Histogrammvergleich der Graustufenbilder zwischen der Standardnachbearbeitung (rot) und der modifizierten Nachbearbeitung (blau).	148

Tabellenverzeichnis

Tabelle 1: Übersicht der Meilensteine in KI Wissen	24
Tabelle 2: Übersicht der Deliverables in KI Wissen	25
Tabelle 3: Struktur von TP1	49
Tabelle 4: Die mean average precision von Auto und Fußgänger für PointPillars mit verschiedenen Kombinationen von GT-Sampling-Methoden. Die linken Werte für jede Zelle sind ohne Polygon. Die Werte neben den Netznamen sind die Baseline Ergebnisse ohne GT-Sampling. Die ausgewiesenen Werte sind der Median von jeweils sechs Trainings. Höhere Werte sind besser. Die besten Ergebnisse sind fett markiert.	56
Tabelle 5: Die mean average precision von Auto und Fußgänger für CenterPoint mit verschiedenen Kombinationen von GT-Sampling-Methoden. Die linken Werte für jede Zelle sind ohne Polygon. Die Werte neben den Netznamen sind die Baseline Ergebnisse ohne GT-Sampling. Die ausgewiesenen Werte sind der Median von jeweils sechs Trainings. Höhere Werte sind besser. Die besten Ergebnisse sind fett markiert.	57
Tabelle 6: Vergleich der Netze Background Aware Shared Resnet (BAST) und Background Aware Individual Resnet (BAIR).....	69
Tabelle 7: Struktur von TP2	80
Tabelle 8: Struktur von TP3	94
Tabelle 9: Detektionskonfidenzen für erkannte Fahrzeugobjekte unterschiedlicher Farbe. Variationen zwischen roten und blauen RGB-Werte für die Fisheye-Kamera 0.	105
Tabelle 10: Detektionskonfidenzen für erkannte Fahrzeugobjekte unterschiedlicher Farbe für die Fisheye-Kamera 5	106
Tabelle 11: Struktur von TP4	112
Tabelle 12: Taxonomiematrix zur Charakterisierung von KI-basierten Konformitätsprüfungen.	115
Tabelle 13: Status bei der Erstellung von synthetischen Szenarien.....	131
Tabelle 14: Struktur von TP5	149
Tabelle 15: Übersicht der bewilligten Kostenpositionen	153
Tabelle 16: Nutzung und Verwertung der Ergebnisse von KI Wissen.....	155

1 Zusammenfassung

Zusammenfassung

Das Projekt KI Wissen ist ein Projekt der KI Familie. Es wurde aus der VDA Leitinitiative autonomes und vernetztes Fahren initiiert und entwickelt und vom Bundesministerium für Wirtschaft und Klimaschutz gefördert. Der hier vorliegende Abschlussbericht beschreibt die Arbeiten und Ergebnisse des Projektpartners Valeo Schalter und Sensoren GmbH (kurz Valeo). Valeo war an allen Teilprojekten beteiligt. Das Ziel von KI Wissen war die Integration von bestehendem Wissen in die Entwicklung und Anwendung von KI-Algorithmen.

Valeo strebte im Rahmen des AP1.1 an, die Fahrzeug- und Fußgängerdetektion basierend auf Daten bildgebender Sensoren durch Verwendung von a priori Wissen zu verbessern. Der Fokus lag hierbei auf Kameradaten. Verschiedene Modelle von Fahrzeugen und auch Fußgängern sowie Wissen über Umgebungsbedingungen wie Wetter wurden in den Trainingsprozess einer bestehenden Perzeptionsmethode eingebracht. Ziel war die Integration dieser Modelle im Input für das neuronale Netz oder auch in der Loss Funktion des Netzes. Durch diese Integration physikalischen Wissens sollte eine erhöhte Präzision und Zuverlässigkeit der Prädiktionsergebnisse erreicht werden.

Valeo hatte in TP2 den Schwerpunkt auf der Vorhersage von Konzepten im Bereich der Sensordatenverarbeitung. In AP2.2 wurden die in TP1 entwickelten Methoden zur Objekterkennung und Sensoreigendiagnose kombiniert, um einen Ansatz zur Situationserkennung umzusetzen. Dabei sollte untersucht werden, inwieweit sich parametrische Veränderungen der Szene wie beispielsweise die Objektfarbe auf die Detektionsgüte auswirken. Daraus konnte Wissen abgeleitet werden, welches zur Plausibilisierung der Methoden in TP3 verwendet wurde. Weiterhin sollte aus der Relation von erkannten Objekten eine Aussage über die Kritikalität einer Situation abgeleitet werden können.

In TP3 übernahm Valeo die Leitung. Es wurde eine Plausibilisierung und Absicherung der von Valeo in AP1.1 und AP1.2 entwickelten Netzwerke durch gezielte Manipulation der Input-Daten angestrebt. In AP3.1 und AP3.2 wurden die Methoden auf unzureichend durch das System erfassten a priori Wissen untersucht und die Ergebnisse an TP1 zurückgespielt. Die Plausibilitätsprüfung der Methoden aus AP1.1 und AP1.2 mit dem aus TP2 gewonnenem Wissen wurde von Valeo in AP3.3 durchgeführt. In AP3.4 wurde eine Plausibilitätsprüfung der Situationserkennung aus AP2.2 über eine Kombination der Methoden aus AP3.1-AP3.3 durchgeführt.

Valeo widmete sich im Rahmen des TP4 in AP4.1 mit der Entwicklung von Metriken für die Einzelkomponenten, wie zum Beispiel der Objekterkennung, und wirkte bei der Definition der Use Cases mit. In AP4.2 beteiligte sich Valeo an der Definition eines Gesamtsystems und seiner einzelnen Komponenten. Dabei brachte Valeo ihre Erfahrungen zu praxisrelevanten Problemen beim Anwenden von KI-Methoden ein. Ein Schwerpunkt lag hierbei auf der Definition der verwendeten Datentypen. In AP4.3 wirkte Valeo beim Einbinden der Komponenten in den Stack mit. In AP4.4 wurden für das Projekt benötigte Kamera und LiDAR Daten aufgenommen. Die in TP1-3 entwickelten Methoden wurden in AP4.5 in den Demonstrator integriert und evaluiert.

Summary

The KI Wissen project is a project of the KI family. It was initiated and developed from the VDA flagship initiative autonomous and connected driving and funded by the Federal Ministry for Economic Affairs and Climate Protection. This final report describes the work and results of the project partner Valeo Schalter und Sensoren GmbH (Valeo for short). Valeo was involved in all sub-projects. The aim of KI Wissen was to integrate existing knowledge into the development and application of AI algorithms.

As part of AP1.1, Valeo aimed to improve vehicle and pedestrian detection based on data from imaging sensors by using a priori knowledge. The focus here was on camera data. Various models of vehicles and pedestrians as well as knowledge about environmental conditions such as weather were introduced into the training process of an existing perception method. The aim was to integrate these models in the input for the neural network or in the network's loss function. This integration of physical knowledge was intended to increase the precision and reliability of the prediction results.

In TP2, Valeo focused on the prediction of concepts in the field of sensor data processing. In AP2.2, the methods developed in TP1 for object recognition and sensor self-diagnosis were combined in order to implement an approach for situation recognition. The aim was to investigate the extent to which parametric changes in the scene, such as object color, affect the detection quality. Knowledge could be derived from this, which was used to check the plausibility of the methods in SP3. Furthermore, it should be possible to derive a statement about the criticality of a situation from the relationship between detected objects.

Valeo took the lead in TP3. The aim was to check the plausibility and validate the networks developed by Valeo in AP1.1 and AP1.2 through targeted manipulation of the input data. In AP3.1 and AP3.2, the methods were examined for insufficient a priori knowledge captured by the system and the results were fed back to TP1. The plausibility check of the methods from AP1.1 and AP1.2 with the knowledge gained from TP2 was carried out by Valeo in AP3.3. In AP3.4, a plausibility check of the situation recognition from AP2.2 was carried out using a combination of the methods from AP3.1-AP3.3.

In AP4.1, Valeo was involved in the development of metrics for the individual components, such as object recognition, and helped to define the use cases. In AP4.2, Valeo participated in the definition of an overall system and its individual components. In doing so, Valeo contributed its experience of practical problems in the application of AI methods. One focus here was on the definition of the data types used. In AP4.3, Valeo was involved in integrating the components into the stack. In AP4.4, the camera and LiDAR data required for the project were recorded. The methods developed in TP1-3 were integrated into the demonstrator and evaluated in AP4.5.

2 Übersicht

2.1 Aufgabenstellung

Autonomes und vernetztes Fahren wird ein zentraler Bestandteil des Mobilitätskonzepts der Zukunft und damit auch wirtschaftlich von herausragender Bedeutung sein. Als einer der Schlüsselfaktoren bei der Umsetzung automatisierter Fahrfunktionen wird aktuell die Verwendung von Algorithmen gesehen, die Methoden der Künstlichen Intelligenz (KI) einsetzen.



Abbildung 1: KI Wissen: Kombination von daten- und regelbasierten Verfahren

KI-Systeme müssen umfassend trainiert, validiert und getestet werden. Bisher erfolgen diese Prozesse in der Regel rein datenbasiert. Dabei werden große Mengen an Trainingsdaten benötigt, deren Beschaffung und Annotation (bei Realdaten) bzw. deren Generierung (bei synthetischen Daten) mit erheblichen Kosten und zeitlichem Aufwand verbunden sind. Neben der Abhängigkeit von umfangreichen Datenmengen weisen die modernen KI-Verfahren eine weitere Schwäche auf: KI-Funktionen sind nach wie vor in der Regel Black-Box-Modelle, deren Entscheidungsfindung nicht direkt nachvollzogen werden kann.

Bisherige Forschungsansätze konzentrieren sich bei der Lösung dieser Fragestellungen auf Optimierung der für das Training und die Absicherung von KI notwendigen Daten.

KI Wissen ging diese Herausforderung auf eine neuartige Art und Weise an und entwickelte Methoden und Tools zur Einbindung von Wissen in das maschinelle Lernen. Dies ist auch in Abbildung 1 dargestellt. Ziel von KI Wissen war die Erschaffung eines umfassenden Ökosystems für die Einbindung von Wissen in das Training und die Absicherung von KI-Funktionen. Die im Projekt erzielten Ergebnisse werden maßgeblich auf zentrale Problemstellungen auf dem Weg zum autonomen Fahren einzahlen: die Steigerung der funktionalen Güte, die Dateneffizienz, die Plausibilisierung und die Absicherung von KI-gestützten Funktionen.

Zur Erreichung dieser Zielsetzung wurde in KI Wissen dezidiert breit geforscht: Es wurden sowohl Methoden zur Wissensintegration als auch Ansätze zur Wissensextraktion und Wissenskonformität entwickelt. Darüber hinaus wurden verschiedene Wissensarten betrachtet. Die im Projekt

entwickelten Ansätze wurden anhand drei definierter Use Cases evaluiert und demonstriert. Durch eine breit angelegte Evaluation und Demonstration wurde die Leistungsfähigkeit der betrachteten Ansätze überprüft und gegeneinander gestellt, um so die für die Industrie relevanten und automotive-tauglichen Methoden identifizieren und weiterentwickeln zu können.

Die Projektstruktur umfasste vier inhaltliche Teilprojekte sowie ein organisatorisches:

- Die drei Kernthemen Wissensintegration, Wissensextraktion und Wissenskonformität wurden in dedizierten Teilprojekten verfolgt (TP1-TP3).
- Für die Evaluation und Demonstration wurde das TP4 vorgesehen.
- Das TP5 koordinierte die Arbeiten, bereitete fortlaufend den Stand der Forschung auf und legte die Grundlagen für die Kommunikation der Ergebnisse an die relevanten Stakeholder (u.a. VDA-LI, Wissenschaft, Standardisierungsgremien im Bereich der Wissensrepräsentation).

Die im Projekt KI Wissen entwickelten Ansätze sind zentrale Bausteine für schnelle Produktentwicklungszyklen von zukünftigen Generationen von KI-basierten Systemen und somit für die zukünftige Wettbewerbsfähigkeit und Wertschöpfung der deutschen Automobil- und Zuliefererindustrie. Als Projekt und als Teil der KI-Projektfamilie der VDA-Leitinitiative leistete KI Wissen somit einen wesentlichen Beitrag zur großflächigen Realisierung hoch automatisierter und autonomer Fahrzeuge, die die zukünftige Mobilität insgesamt sicherer und effizienter machen werden.

1. Inhaltliche Schwerpunkte des Partners Valeo

Valeo beteiligte sich an allen Teilprojekten. Valeo strebte im Rahmen des AP1.1 an, die Fahrzeug- und Fußgängerdetektion basierend auf Daten bildgebender Sensoren durch Verwendung von a priori Wissen zu verbessern. Der Fokus lag hierbei auf Kameradaten. Verschiedene Modelle von Fahrzeugen und auch Fußgängern sowie Wissen über Umgebungsbedingungen wie Wetter wurden in den Trainingsprozess einer bestehenden Perzeptionsmethode eingebracht. Ziel war die Integration dieser Modelle im Input für das neuronale Netz oder auch in der Loss Funktion des Netzes. Durch diese Integration physikalischen Wissens sollte eine erhöhte Präzision und Zuverlässigkeit der Prädiktionsergebnisse erreicht werden.

Valeo hatte in TP2 den Schwerpunkt auf der Vorhersage von Konzepten im Bereich der Sensordatenverarbeitung. In AP2.2 wurden die in TP1 entwickelten Methoden zur Objekterkennung und Sensoreigendiagnose kombiniert, um einen Ansatz zur Situationserkennung umzusetzen. Dabei sollte untersucht werden, inwieweit sich parametrische Veränderungen der Szene wie beispielsweise die Objektfarbe auf die Detektionsgüte auswirken. Daraus konnte Wissen abgeleitet werden, welches zur Plausibilisierung der Methoden in TP3 verwendet wurde. Weiterhin sollte aus der Relation von erkannten Objekten eine Aussage über die Kritikalität einer Situation abgeleitet werden können.

In TP3 übernahm Valeo die Leitung. Es wurde eine Plausibilisierung und Absicherung der von Valeo in AP1.1 und AP1.2 entwickelten Netzwerke durch gezielte Manipulation der Input-Daten angestrebt. In AP3.1 und AP3.2 wurden die Methoden auf unzureichend durch das System erfassten a priori Wissen untersucht und die Ergebnisse an TP1 zurückgespielt. Die Plausibilitätsprüfung der

Methoden aus AP1.1 und AP1.2 mit dem aus TP2 gewonnenem Wissen wurde von Valeo in AP3.3 durchgeführt. In AP3.4 wurde eine Plausibilitätsprüfung der Situationserkennung aus AP2.2 über eine Kombination der Methoden aus AP3.1-AP3.3 durchgeführt.

Valeo widmete sich im Rahmen des TP4 in AP4.1 mit der Entwicklung von Metriken für die Einzelkomponenten, wie zum Beispiel der Objekterkennung, und wirkte bei der Definition der Use Cases mit. In AP4.2 beteiligte sich Valeo an der Definition eines Gesamtsystems und seiner einzelnen Komponenten. Dabei brachte Valeo ihre Erfahrungen zu praxisrelevanten Problemen beim Anwenden von KI-Methoden ein. Ein Schwerpunkt lag hierbei auf der Definition der verwendeten Datentypen. In AP4.3 wirkte Valeo beim Einbinden der Komponenten in den Stack mit. In AP4.4 wurden für das Projekt benötigte Kamera und LiDAR Daten aufgenommen. Die in TP1-3 entwickelten Methoden wurden in AP4.5 in den Demonstrator integriert und evaluiert.

Die konkreten Arbeitsaufgaben des Partners Valeo können zudem dem Kapitel 2.3 „Planung und Ablauf des Vorhabens“ entnommen werden.

2.2 Voraussetzungen für das Vorhaben

Das Verbundvorhaben KI Wissen wurde im Rahmen des BMWK (damals noch BMWi)-Fachprogramms „Neue Fahrzeug- und Systemtechnologien“ zur Förderung eingereicht. Die Ziele und intendierten Wirkungen des Vorhabens standen im Einklang mit den Zielsetzungen und Schwerpunkten des Förderprogramms.

Darüber hinaus wies das Vorhaben KI Wissen eine Reihe von Bezügen sowohl zu der von der Bundesregierung im November 2018 veröffentlichten „Strategie Künstliche Intelligenz“ als auch zu dem im Juni 2020 verabschiedeten Konjunkturprogramm „Corona-Folgen bekämpfen, Wohlstand sichern, Zukunftsfähigkeit stärken“ auf.

Das BMWK-Fachprogramm formulierte als Hauptziel die „Stärkung der industriellen und wissenschaftlichen Innovationskraft Deutschlands im Bereich des automatisierten Fahrens“ [1].

Das Verbundvorhaben KI Wissen leistete einen zentralen Beitrag zur Stärkung der Wettbewerbsfähigkeit des Wirtschafts- und Wissenschaftsstandorts Deutschland. Durch das Projekt wurden die nationale Automobilindustrie und Forschungslandschaft befähigt, bestehende Kompetenzen [1] für eine Schlüsseltechnologie im Bereich des autonomen und vernetzten Fahrens auf- und auszubauen. Die Aufrechterhaltung und der Ausbau der Innovationskraft der deutschen Automobilindustrie allgemein und insbesondere auch der Automobilzulieferer ist von erheblichem Bundesinteresse, da es langfristig zur Generierung von Wertschöpfung am Standort Deutschland beiträgt.

Mit Blick auf den zu erwartenden Mehrwert und Chance für die deutsche Industrie hat sich KI Wissen das Zusammenbringen von datenbasierten KI-Verfahren und wissensbasierten Methoden als Aufgabe gestellt. Dabei werden drei Linien verfolgt:

- Durch die Integration von Wissen in KIs können benötigte Daten und Rechenleistung zum Training reduziert und gleichzeitig die Generalisierungsfähigkeit gesteigert werden.
- Durch die Extraktion von Wissen aus KIs kann die Nachvollziehbarkeit der Entscheidungen deutlich erhöht werden.

- Durch die Prüfung der Konformität von KI-Entscheidungen zu Wissen können Inkonsistenzen aufgedeckt und entsprechende Gegenmaßnahmen unternommen werden.

2. Operative Projektsteuerung

Das Vorhaben KI Wissen folgte einer Mehrebenenorganisation, die auf operativer Ebene die Gremien Projektmanagementteam (PMT), Teilprojektleitung (TPL) und Arbeitspaketleitung (APL) umfasste. Hier kamen die für effiziente Zusammenarbeit erforderlichen Methoden und Werkzeuge zum Einsatz. Die vorgesehenen erfahrenen technischen Projektmitarbeiter wurden von professionellen Projektmanagementexperten unterstützt (vgl. GUA1 „Management und Koordination“).

3. Ergebnisverbreitung

Aufgrund der beschriebenen Relevanz und Dringlichkeit des Themas für den Wirtschaftsstandort Deutschland strebte das Konsortium eine weitere, über das Einzelprojekt hinausgehende Wirkung an. Damit stellten sich besondere Anforderungen an die Vernetzung und den Ergebnistransfer. Dies betraf sowohl die projektinterne Zusammenarbeit als auch die Kooperation nach außen. Hier hatte insbesondere die Zusammenarbeit mit TPX hohe Relevanz für das Einlösen der Synergiepotentiale aus den übergreifenden Prozessen von Ergebnistransfer und Ergebnisverbreitung in der KI-Projektfamilie.

4. Projektorganisation

Die Projektorganisation teilte sich in die strategische und operative Ebene auf und ist in Abbildung 2 dargestellt.




Abbildung 2: Projektorganisation

Neben dieser Projektorganisation gab es noch eine Reihe von übergreifenden Themen, wie dem TPX und einigen Arbeitsgruppen, die TP und AP übergreifend agierten.

1. Projektbezogene Kompetenzen des Partners Valeo

Zum Abschluss sollen noch die projektbezogenen Kompetenzen des Partners VALEO kurz beschrieben werden.

Valeo brachte Kenntnisse aus Algorithmik für Ultraschall, Radar, Lidar, Kameras und Laser-Scannern in das Vorhaben KI Wissen ein. Insbesondere in den Bereichen künstlicher Intelligenz ist Valeo sehr stark aktiv. Als global agierende Firma ist das Thema der Wissensintegration sehr relevant, da entwickelte Sensoren und Algorithmen im besten Fall überall einsatzbereit sind.

Valeo ist und war in vielen deutschen wie auch europäischen Forschungsprojekten vertreten. Nennenswert sind dabei in Bezug auf KI Wissen Projekte wie ADAS&me, Cloud LSVA, KI Absicherung, KI Data Tooling, KI Delta Learning, Providentia++, UNICARagil, VVMethoden.

KI-Absicherung, KI-Data Tooling und KI Delta Learning nehmen eine besondere Stellung ein; als Schwesterprojekte in der KI-Familie, welche zu großen Teilen parallel zu KI Wissen liefen. Da Valeo an allen Projekten beteiligt war, wurden vor allem intern Synergien genutzt und die Entwickler standen in engem Austausch.

Eine detaillierte Darstellung der weiteren Forschungsprojekte ist in Kapitel 2.4 zu finden.

2.3 Planung und Ablauf

2.3.1 Projektstruktur

Das Vorhaben startete am 01.01.2021 und endete am 31.03.2024. Das Projekt war unterteilt in fünf Teilprojekte TP 1-5, wobei TP1-4 inhaltlicher Natur waren und TP5 für die Projektorganisation.

Abbildung 3 visualisiert den Gesamtansatz von KI Wissen und liest sich von links nach rechts. Das Ziel der Verknüpfung von Wissen mit KI-basierten Ansätzen setzt voraus, dass auch entsprechendes Wissen verfügbar ist. Hierfür mussten geeignete Wissensquellen identifiziert werden (z.B. StVO, gerichtliche Urteile, physikalische Fachbücher, Unfalldatenbanken), um für das autonome Fahren relevantes Automotive-Wissen zu aggregieren. Dieses Wissen musste anschließend durch geeignete Methoden zur Modellierung und Formalisierung in ein maschinen-interpretierbares Format überführt werden, da einfacher Text, wie er in der Literatur üblich ist, nicht von Computern verarbeitet werden kann. Bei der Formalisierung wurde zwischen Anwendungswissen und Absicherungswissen differenziert, denn je nach Anwendungszweck (Wissensintegration vs. Wissenskonformität) können sich die Anforderungen an die Formalisierung und somit auch ihre konkrete Realisierung unterscheiden.

Für die Umsetzung der Wissensintegration mussten Methoden für wissensbasiertes Training entwickelt werden. Zusammen mit dem formalisierten Wissen konnten so wissensbasiert trainierte KI-Komponenten erzeugt werden, die beispielsweise Wissen über die Dynamik, StVO, mögliche Aktionen von Verkehrsteilnehmern oder gewissen Verteilungen beinhalten. Durch die Entwicklung von Methoden zur Extraktion von Wissen und Konzepten sollte die Wissensextraktion von Netzwissen aus trainierten KI-Komponenten realisiert werden. Die Wissenskonformität wurde durch geeignete Methoden zur Plausibilisierung von KI-Komponenten auf Basis des formalisierten Wissens geprüft.

Um die in KI Wissen entwickelten Verfahren und trainierten KI-Komponenten bewerten zu können, mussten geeignete Gütemetriken entwickelt werden, die die Verfahren/Modelle in Punkten wie Funktionalität, Trainingsaufwand, Plausibilität, Konformität, Konsistenz und mehr bewerteten. Für diese Evaluation wurde ein Datenpool notwendig, auf dessen Datenpunkten die Evaluation entsprechend durchgeführt werden konnte. Neben der quantitativen Evaluation durch Gütemetriken wurde auch eine qualitative Evaluation durch die Überführung der Innovationen in Demonstratoren realisiert. Die Ergebnisse der Evaluation flossen wieder zurück in alle vorherigen Prozessschritte, sodass die dort entwickelten Methoden qualifiziert und entsprechend weiterentwickelt werden konnten.




Abbildung 3: Gesamtansatz von KI Wissen

In Abbildung 4 sind alle TPs mit ihren zugehörigen Arbeitspaketen (AP) dargestellt.




Abbildung 4: Projektierungsansatz, inklusive Verantwortlichkeiten der Teilprojekte

2.3.2 Zeitlicher Ablauf

Das Projekt KI Wissen bearbeitete die gesetzten Ziele in einer Laufzeit von drei Jahren und wurde durch eine kostenneutrale Projektlaufzeitverlängerung um drei Monate bis zum 31.03.2024 verlängert. Aufgrund seines iterativen Vorgehens wurde KI Wissen in drei aufeinanderfolgenden Projektschritten, sog. Projekt-Inkrementen bearbeitet, wobei PI1 und PI2 jeweils 12 Monate Laufzeit hatten und PI3 durch die Verlängerung der Projektlaufzeit auf 15 Monate Laufzeit kam. Abbildung 5 zeigt die ursprüngliche Planung der Projekt-Inkmente ohne kostenneutrale Verlängerung. Die Projekt-Inkmente 1 und 2 schlossen jeweils mit einem Review und der weiteren Ausplanung des nächsten Projekt-Inkments ab. Innerhalb der drei Projekt-Inkmente liefen relativ ähnliche und sich wiederholende Prozesse ab. Die Arbeiten innerhalb der Projekt-Inkmente werden im Folgenden näher beschrieben.




Abbildung 5: Ursprüngliche Planung der Inkrementellen Projektdurchführung ohne kostenneutrale Verlängerung. Der detaillierte Zeitplan mit kostenneutraler Verlängerung ist in Abbildung 6 dargestellt

Projekt-Inkrement 1 (PI1): Konzeption und Prototyping

Es wurde eine detaillierte Analyse und Zusammentragung des aktuellen Standes der Wissenschaft und Technik zur Verknüpfung von datengetriebenen KI-Verfahren mit bestehendem Wissen umgesetzt. Zusätzlich wurde geeignetes Domänenwissen identifiziert und charakterisiert, das für die Wissensintegration und Wissenskongruenz eingesetzt werden sollte. Erste Konzepte zur Formalisierung des Wissens wurden entwickelt.

Basierend auf dem beschriebenen Stand der Wissenschaft und Technik wurden erste Konzepte erarbeitet, um bekanntes Wissen in KI-Verfahren zu integrieren, gelerntes Wissen aus bestehenden KI-Modellen zu extrahieren sowie Vorhersagen und Entscheidungen von KI-Modellen auf ihre Kongruenz zu bekanntem Wissen zu prüfen.

Parallel wurden die Use Cases detailliert ausgearbeitet und es wurden entsprechende Szenarien definiert. Zur Evaluation der Use Cases wurden erste Gütekriterien und Metriken definiert. Zur Demonstration der geplanten Arbeiten wurde ein Gesamtsystem konzeptioniert, Schnittstellen definiert und die Implementierung begonnen.

Erste Ansätze wurden prototypisch realisiert und evaluiert, um die Entwicklung der Konzepte weiter voranzutreiben.

Projekt-Inkrement 2 (PI2): Implementierung und Zwischenevaluation

Auf Basis der ersten prototypischen Realisierungen, deren Evaluation sowie externen Veröffentlichungen wurde der Stand der Wissenschaft und Technik fortgeschrieben. Darauf aufbauend wurden die Konzepte weiterentwickelt, sodass anschließend mit der Implementierung der Konzepte begonnen werden konnte. Mit Hilfe der entwickelten Formalisierungsverfahren wurden erste formalisierte Wissensbausteine abgeleitet, die dann für die Wissensintegration und Wissenskongruenz zur Verfügung standen.

Für das Vorhaben KI Wissen wurden drei Projektmeilensteine (MS1-MS3) definiert, anhand derer der Projektfortschritt und -erfolg erfasst werden soll (siehe Tabelle 1). Die zeitliche Verortung der Projektmeilensteine ist in Abbildung 6 dargestellt. Zum ersten Meilenstein lag ein starkes Gewicht

auf wissenschaftlichen Berichten, während die konkrete Umsetzung durch die Industriepartner in den darauffolgenden Projekt-Inkrementen folgte und zu MS2 und MS3 umgesetzt wurde. MS3 stellt gleichzeitig den Projektabschluss dar.

Tabelle 1: Übersicht der Meilensteine in KI Wissen

ID	Titel	Fälligkeit	Erfüllungskriterien
MS1	Konzeption und Prototyping Die Gesamtkonzeption zur Formalisierung von Wissen liegt vor. Die prototypische Umsetzung erster Elemente ist erfolgt und Evaluationskriterien wurden entwickelt.	M12	D1, D2, D3, D4, D7
MS2	Implementierung und Zwischenevaluation Die entwickelten Formalisierungsverfahren, Gütekriterien und Metriken wurden weiterentwickelt und in den Demonstrator integriert. Die Use-Case-basierte Zwischenevaluation liegt vor.	M24	D1, D2, D3, D4, D5, D6, D7
MS3	Optimierung und Gesamtevaluation Die weiter optimierten Verfahren sind zu einem Baukasten wissensbasierter KI-Verfahren zusammengeführt. Alle Elemente sind in das Gesamtsystem integriert, wurden umfassend evaluiert und demonstriert.	M39	D1, D2, D3, D4, D5, D6, D7

Das Projekt KI Wissen hat insgesamt sieben Deliverables definiert (siehe Tabelle 2: Übersicht der Deliverables in KI Wissen), die der Ergebnisdokumentation nach innen sowie nach außen dienen. Sie orientierten sich inhaltlich an den technischen und wissenschaftlichen Projektinnovationen wobei sich jedes Deliverable eindeutig einer Projektinnovation zuordnen lässt.

Die Deliverables wurden größtenteils aus den Ergebnissen mehrerer Arbeitspakete gespeist, woraus sich eine starke Vernetzung ergab, welche die Zusammenarbeit im Konsortium stärken und Synergien heben sollte. Zum Projektstart wurde ein Vorgehen entwickelt, das die effiziente Steuerung des Erstellprozesses der Deliverables sicherstellte. Dabei wurde - soweit durch die Art des Deliverables möglich - ein modularer Aufbau gewählt, der den drei Freigabestufen Rechnung trägt und kumulativ die Ergebnisse aus neuen Phasen aufnimmt.

Die Deliverables setzten sich aus den insgesamt 49 Ergebnissen zusammen, die innerhalb der Arbeitspakete in den Teilprojekten 1-4 erarbeitet wurden. Eine Zuordnung der Ergebnisse zu den Deliverables ist in Tabelle 2 zusammengefasst.

Tabelle 2: Übersicht der Deliverables in KI Wissen

ID	Titel	Ergebnisform	Fälligkeit	Hauptverantwortlich	TP1	TP2	TP3	TP4
D 1	Katalog, Charakterisierung und Repräsentation von relevantem Domänenwissen für L3 bis L5 Fahrfunktionen	Dokument	M12, M24, M39	FZI	E1.3.1, E1.3.2, E1.3.3, E1.4.1, E1.4.2, E1.4.3, E1.5.1, E1.5.2, E1.5.3	E2.1.2, E2.1.4	E3.1.1, E3.1.2, E3.1.3, E3.2.1, E3.2.2, E3.2.3, E3.4.1	
D 2	Lerntechniken zur Integration von formalisiertem Wissen und von Netzwissen zur Trainingsreduktion und Performanzverbesserung	Dokument/ White paper	M12, M24, M39	DFKI	E1.1.1, E1.1.2, E1.1.3, E1.2.1, E1.2.2, E1.2.3,			
D 3	Methoden zur Gewinnung von Wissen aus einer datengetriebenen KI-Funktion	Dokument	M12, M24, M39	Fraunhofer		E2.1.1, E2.1.2, E2.1.3, E2.1.4, E2.2.1, E2.2.3, E2.3.1, E2.3.2, E2.3.3		
D 4	Methoden zur datenunabhängigen Validierung der Vorhersagen und Entscheidungen einer KI-Funktion	Dokument	M12, M24, M39	OFFIS			E3.1.1, E3.1.2, E3.1.3, E3.2.1, E3.2.2, E3.2.3, E3.3.1, E3.4.1, E3.4.2,	
D 5	Wiederverwendbare, qualifizierte und formalisierte Bausteine aus Anwendungs-, Absicherungs- und Netzwissen	Software und Spezifikationen	M24, M39	Continental	E1.3.3, E1.4.3, E1.5.3	E2.2.3, E2.3.3	E3.1.2, E3.1.3, E3.2.2, E3.2.3, E3.3.1,	E4.2.1
D 6	Baukasten wissensbasierter KI-Verfahren für Unternehmen und Forschung	Software und Spezifikationen	M24, M39	Valeo	E1.1.2, E1.1.3, E1.2.3	E2.1.2, E2.2.2, E2.3.2	E3.1.2, E3.1.3, E3.2.2, E3.2.3, E3.3.2, E3.4.2,	E4.2.1, E4.2.2, E4.2.3, E4.2.4, E4.3.1, E4.3.2, E4.3.3
D 7	Demonstratoren mit KI-Komponenten	Software und Spezifikationen /Demonstration	M12, M24, M39	AVL				E4.1.1, E4.1.2, E4.2.3, E4.3.1, E4.3.2, E4.3.3, E4.4.1, E4.4.2, E4.4.3, E4.5.1, E4.5.2

2.4 Stand der Wissenschaft und Technik

Bevor die KI-Forschung die Renaissance der neuronalen Netzwerke im Jahr 2012 [10] vollzog, war die Einbettung von Experten- und Domänenwissen nicht nur hilfreich, sondern notwendig, um maschinelle Lernalgorithmen zur Lösung anwendungsnaher Problemstellungen einsetzen zu können. Die hierbei zum Einsatz gebrachten Techniken sind unter dem Begriff Feature Engineering zusammengefasst und haben das Ziel, Eingabedaten durch bekannte Zusammenhänge so zu transformieren, dass sich eine möglichst einfache, d.h. niedrigdimensionale und durch Kombination linearer Funktionen darstellbare, Repräsentation der Daten ergibt.

Tiefe neuronale Netzwerke automatisieren das Feature Engineering und lernen diese Repräsentationen aus großen Mengen, häufig detailliert annotierter Daten. Dies erlaubt die Entwicklung neuer Verfahren unabhängig von der Anwendungsdomäne, also auch ohne explizit zu formulierendes Expertenwissen, und hat (trotzdem) in nahezu allen KI-Forschungs- und Industriezweigen zu bisher ungekannter Prädiktionsgüte geführt.

Gleichzeitig wird die Einsetzbarkeit von rein datengetriebenen Methoden in verschiedenen Anwendungsbereichen durch zwei wesentliche Faktoren gehemmt. Zum einen durch den Bedarf an umfangreichen Datenmengen, in denen auch bereits bekannte Sachverhalte mit statistischer Signifikanz automatisiert hergeleitet werden können. Zum anderen durch die mangelhafte Nachvollziehbarkeit und Transparenz der erlernten und zum Teil sehr komplexen Modelle. Hinzu kommt, dass eine fehlende mathematische Theorie tiefer neuronaler Netze, eine gezielte, d.h. nicht ausschließlich durch Empirie geleitete, Weiterentwicklung erschwert.

Das Vorhaben verfolgte die drei Stränge Wissensintegration, Wissensextraktion und Wissenskonformität, um die Mängel von datengetriebenen KI-Ansätzen zu reduzieren. Hierfür konnte auf einen breiten Fundus verschiedener Methoden zurückgegriffen werden, aus dem im Projekt KI Wissen problemspezifisch passende Methoden ausgewählt und im Rahmen des Projekts weiterentwickelt wurden. Im Folgenden wird der Stand der Wissenschaft und Technik beschrieben, an den KI Wissen angeknüpft hat.

5. Ansätze und Grundbausteine der KI-Forschung

1. Katalog, Charakterisierung und Repräsentation von relevantem Domänenwissen für L3 bis L5 Fahrfunktionen

Der Mensch gibt sein erworbenes Wissen stets an die nächste Generation weiter, sei es in Form von Sprache oder Schrift, sodass über die Jahrtausende immer weitere Zusammenhänge aufgeklärt werden konnten. Mathematik, Physik, Biologie, Chemie, Astronomie, Philosophie, Psychologie, Ethik, Religion, Linguistik, Technik, Informatik, Medizin, Landwirtschaft, Handwerk, Soziologie, Wirtschaft, Recht [11] und noch viele weitere Disziplinen zeigen auf, wie vielfältig das menschlich aggregierte Wissen ist. Dennoch haben viele dieser Disziplinen die Gemeinsamkeit, dass das Wissen eines Menschen durch schriftliche Abhandlungen an eine breite Leserschaft weitergegeben wird. Zwar mag diese Art des Wissenstransfers für den Menschen sehr gut geeignet sein, so ist sie für eine Maschineninterpretierbarkeit aber eher weniger geeignet. Um nun aber vorhandenes Wissen für KI-Verfahren nutzen zu können, ist eben diese maschinelle Interpretierbarkeit des Wissens von größter Wichtigkeit. Somit ergibt sich die Notwendigkeit, existierendes Wissen durch geeignete Formalisierungs- bzw. Modellierungsansätze in ein Format zu transformieren, das eine Integration des Wissens in KI-Komponenten bzw. eine Plausibilisierung von KI-Entscheidungen ermöglicht.

Die Mathematik bietet einen großen Werkzeugkasten an, mit dem Zusammenhänge formalisiert werden können. Insbesondere physikalische Zusammenhänge werden in der Regel durch mathematische Modellierungen beschrieben, oftmals durch algebraische oder Differenzialgleichungen [12]. Im Kontext des autonomen Fahrens spielen physikalische Gesetzmäßigkeiten eine wichtige Rolle, da bspw. Bewegungsgleichungen für die Vorhersage der Bewegung des eigenen als auch von anderen Fahrzeugen eine entscheidende Bedeutung haben. Solches Wissen kann dann z.B. in die klassische Konstruktion eines PID-Reglers zur Realisierung einer Adaptive Cruise Control (ACC) einfließen [13].

Die Vielfalt der zu beschreibenden Zusammenhänge bedingt oft auch unterschiedliche Formen der Wissensrepräsentation, was sich auch wiederum auf die Methoden zur Verwendung der Wissensrepräsentation auswirkt. Hierzu gehören Wissensrepräsentationen in Form formaler Logik [14], in Form bekannter algebraischer oder Differenzialgleichungen [12], in Form probabilistischer Zusammenhänge [15], in Form bekannter Invarianzen von Eingabe- oder Ausgabedaten [16], in Form von Wissensgraphen [17] [18] oder in Form ausführbarer Simulationen [19]. Für solche Wissensrepräsentationen konnten dedizierte Verfahren zur Wissensintegration entwickelt werden, deren Einsatz in realen Anwendungen aber meistens nicht untersucht wurde.

Verfahren aus der Literatur befassen sich oftmals mit physikalischen Gesetzmäßigkeiten. Für das autonome Fahren ist aber auch Wissen über Verhalten von Verkehrsteilnehmern oder über Regularien (z.B. StVO) von großer Bedeutung. Entsprechende Formalismen sind noch recht unterrepräsentiert und meistens nicht mit dem Ziel zur Wissensintegration entwickelt worden. Solche Ansätze können aber entsprechend weiterentwickelt werden, um die entsprechenden Anwendungen zu ermöglichen.

Ein Beispiel einer solchen Wissensrepräsentation sind Traffic Sequence Charts (TSCs) [20] [21] [22]. Ein TSC bildet einen Formalismus, durch den sich eine Familie von Trajektorien auf eindeutige Weise spezifizieren lässt. Um die Formalisierung dem Anwender möglichst einfach zu machen, werden TSCs durch eine visuelle Spezifizierung in Form von abstrakten Szenarien erstellt. Diese können dann automatisch in einen maschineninterpretierbaren Formalismus transformiert werden. So kann mit TSCs eine Spezifikation definiert werden, wie sich ein Fahrzeug in gewissen Szenarien verhalten darf bzw. wie es sich nicht verhalten darf. Somit stellen TSCs bereits ein interessantes Mittel dar, wie z.B. das Wissen darüber, wann ein Spurwechsel durchgeführt werden darf und wann nicht, formalisiert werden kann. TSCs wurden aber nicht direkt zur Formalisierung von physikalischen Gesetzmäßigkeiten oder zur Wissensintegration entwickelt. Eine entsprechende Weiterentwicklung hat demnach großes Potential für das Vorhaben KI Wissen.

2. Lerntechniken zur Integration von formalisiertem Wissen und von Netzwissen zur Trainingsreduktion und Performanzverbesserung

Um relevantes Domänenwissen in KI-basierten Fahrfunktionen zu nutzen, muss es in die KI-Funktion integriert werden. Dies kann auf jeder der drei Ebenen eines AD-Stacks geschehen: auf der Ebene der Sensorik und Umweltwahrnehmung, auf der Ebene des Situationsverständnisses und der Situationsinterpretation als auch auf der Ebene der Entscheidungsfindung, Planung und Regelung.

Die meisten Vorarbeiten und technischen Umsetzungen gibt es sicherlich auf der Ebene der Sensorik und Umweltwahrnehmung. Hier wird klassischerweise Vorwissen über die Sensoren selbst

und ihre Messfehler in datengetriebene Methoden eingebracht. Beispiele sind die Korrektur optischer Abbildungsfehler im Bereich der Bildverarbeitung, Wissen über optische und geometrische Randbedingungen bei der zweidimensionalen Abbildung dreidimensionaler Objekte [23], das Wissen über die Reflektions- und Dispersionseigenschaften bestimmter Materialien im Radarsignal [24] oder Wissen über die Rauschverteilung und Messfehler eines Sensors ganz allgemein.

Dabei ist zu beachten, dass bestehende Methoden im Bereich der Sensorik vorrangig Wissen über den Sensor selbst integrieren, diesen also unabhängig von einer bestimmten Anwendung betrachten. Im Verkehrsbereich kommen Umweltsensoren jedoch in einer hoch strukturierten Umgebung zum Einsatz, so dass auch eine Anpassung an die beobachtete Domain erfolgversprechend ist. Darin besteht einer der Ansatzpunkte von KI Wissen.

Auf der Ebene des Situationsverständnisses und der Situationsinterpretation herrschen in derzeit verfügbaren Fahrerassistenzsystemen regelbasierte Methoden vor. Grund sind die strengen Sicherheitsanforderungen im Fahrzeug (ISO 26262), welche interpretierbare und beweisbar sichere Verfahren notwendig machen. Damit einhergehend bestehen jedoch massive Einschränkungen der Funktionalität. Zur Illustration seien hier einige vom Hersteller Volvo genannte - und durchaus für die gesamte Industrie repräsentative - Auszüge aus den Beschränkungen des Pilot Assist Systems für das Modelljahr 2021 mit Stand vom 18.05.2020 genannt [25]:

- Hohe Bordsteine, Straßensperren, vorübergehende Hindernisse (Verkehrskegel, Sicherheitsbarrieren usw.) werden nicht erkannt. Alternativ können sie fälschlicherweise als Fahrspurmarkierungen erkannt werden, mit der nachfolgenden Gefahr des Kontakts zwischen dem Fahrzeug und solchen Hindernissen. Der Fahrer muss sicherstellen, dass sich das Fahrzeug in angemessenem Abstand von solchen Hindernissen befindet.
- Die Kamera und der Radarsensor sind nicht in der Lage, alle entgegenkommenden Objekte und Hindernisse in Verkehrsumgebungen zu erfassen, z.B. Schlaglöcher, stationäre Hindernisse oder Gegenstände, die die Route ganz oder teilweise blockieren.
- Pilot Assist "sieht" keine Fußgänger, Tiere usw.

Daraus resultieren Einschränkungen für die Nutzbarkeit des Systems

- falls Spurmarkierungen undeutlich, fehlend, sich kreuzend sind oder mehrfach vorhanden sind
- auf Einfädelungsspuren oder im Falle von Spurzusammenführungen oder Teilungen
- falls Kanten oder andere Linien als Fahrspurmarkierungen auf oder in der Nähe der Straße vorhanden sind, z.B. Bordsteine, Fugen oder Reparaturen an der Straßenoberfläche, Kanten von Barrieren, Straßenrändern oder starken Schatten
- falls die Fahrspur eng oder kurvenreich ist oder Rippen/Löcher vorhanden sind
- bei schlechten Lichtverhältnissen, Hintergrundbeleuchtung, nasser Fahrbahnoberfläche usw.

Die bei den Herstellern in der Vorentwicklung befindlichen Systeme versuchen viele dieser Einschränkungen zu reduzieren und setzen hier insbesondere auf den verstärkten Einsatz datengetriebener Methoden im Bereich der Sensorik. Dennoch sollte klar sein, dass allein damit das Grundproblem, nämlich die fehlende Verbindung von Semantik und Interpretation mit der

Sensorik nicht beseitigt werden kann. Hier hat KI Wissen einen weiteren Ansatzpunkt für die Integration von datenbasierten Verfahren mit wissensbasierten Methoden.

Auch auf der Ebene der Entscheidungsfindung, Planung und Regelung finden wir die gleiche Situation vor. Bestehende Systeme setzen aus den oben genannten Gründen derzeit auf rein regelbasierte Ansätze. Diese stoßen jedoch an ihre Grenzen, wenn diese Regeln im Verkehrskontext neu interpretiert werden müssen. Das ist beispielsweise der Fall, wenn die Verkehrssituation eine Ausnahme von der Regel erfordert, etwa, um den Weg für ein Einsatzfahrzeug freizugeben oder um ein Hindernis zu umfahren [26]. Da nicht alle Kombinationen von Regeln, Kontexten und Ausnahmen im Vorhinein manuell zu kodieren sind, will das vorliegende Projekt diese Problemstellungen mit den Methoden der KI angehen.

In der wissenschaftlichen Literatur finden sich bereits eine Vielzahl von Ansätzen zur breiten Integration von Regel-/Wissensbasierten Verfahren mit datenbasierten KI-Methoden. Die berichteten Anwendungen finden sich jedoch häufig außerhalb des Automobilkontextes. Hier setzt KI Wissen an und plant verschiedene bestehende Methoden aus der Wissenschaft auf den Automobilkontext zu übertragen, um sie auf ihre Eignung und resultierende Performanzverbesserung hin zu prüfen.

Aufgrund dieser Diskrepanz im Anwendungsbereich sind bestehende methodische/algorithmische Arbeiten eher nach der Form der Repräsentation des verfügbaren Wissens klassifiziert. Im Folgenden seien die drei wichtigsten Repräsentationsformen mit exemplarischen Integrationsmethoden dargestellt und ihre potentielle Nutzung im Bereich des Autonomen Fahrens skizziert.

1. Physikalisch/Mathematische Randbedingungen

Die Nutzung physikalischer Gesetzmäßigkeiten ist wahrscheinlich die am besten untersuchte Wissenskategorie. Alle Teilbereiche autonomen Fahrens werden tangiert. Von der Sensorik über die Situationsinterpretation bei der Vorhersage der Bewegung anderer Verkehrsteilnehmer bis hin zur eigenen Pfadplanung. Die Berücksichtigung explizit formulierter physikalischer und mathematischer Gesetzmäßigkeiten verspricht einen grundlegenden Zugewinn sowohl in der Generalisierungsfähigkeit von Algorithmen des Maschinellen Lernens, der Effizienz der Datennutzung, als auch in der Lösung ihrer Korrektheitsproblematik gegenüber im Wesentlichen auf statistische Inferenz beschränkten gegenwärtigen Lernverfahren.

In der Literatur finden sich bereits einige Arbeiten, die auf die Integration von physikalischem a priori Wissen abzielen. Dieser Methodenkatalog beinhaltet unter anderem Verfahren, die menschliches a priori Wissen in Form manuell erstellter Modelle mit gelernten neuronalen Netzwerken kombinieren (Hybrid Neural Networks, HNN [27] [28] oder Generalized-constraint neural networks (GCNN) [29]) als auch Verfahren, die in das Training oder die Architektur neuronaler Netze eingreifen.

Im Training können physikalische Randbedingungen als (Regularisierungs-)Terme in der Loss Funktion berücksichtigt werden [30] [31]. Alternativ kann auch das Trainingsverfahren, das die Verlustfunktion minimiert, modifiziert werden, um physikalische Randbedingungen zu berücksichtigen [32].

Beispiele für Netzwerkarchitekturen, die darauf ausgelegt sind, physikalische Probleme mit datengetriebenem Lernen zu kombinieren und gleichzeitig Wissen in die Loss Funktion einfließen lassen, sind Physics Guided Recurrent Neural Networks (PGRNN) [33] und Physics Informed Neural Networks [34], die partielle Differentialgleichungen - also die Sprache der Physik - effizient lösen können. Sie liefern dabei oft sehr gute Ergebnisse bei sehr geringen Berechnungskosten im Vergleich zu herkömmlichen Verfahren.

2. Zustandsräume

Verständnis einer Verkehrssituation erfordert zwingend eine exakte Schätzung des dynamischen Zustandes aller Verkehrsteilnehmer und ihrer Umgebung. Häufig unterliegen dynamische Systeme Randbedingungen, an die alle weitere Dynamik gebunden ist. Exakte Schätzungen des Zustandes sowie Vorhersagen über zukünftige Dynamik erfordern Kenntnis eines Bewegungsmodells und seiner Randbedingungen sowie ferner die Kenntnis der Unsicherheiten des zugrundeliegenden Messprozesses.

Zur Schätzung des dynamischen Zustandes existieren unter bestimmten Voraussetzungen etablierte Verfahren, wie der optimale Bayessche Filter, der als Sonderausprägung des Kalman-Filters [35] besonders verbreitet ist. Diese Filtergruppe stellt im Automotive-Bereich heute den Standard dar für die Auswertung von Radarsignalen oder die Positionsbestimmung sich bewegender GPS-Empfänger. Bayessche Filter, Kalman-Filter, bzw. deren approximative Erweiterungen auf nicht-lineare Systeme wie Extended und Unscented Kalman-Filter Varianten [36], bilden den Grundstock des heutigen Standes der Technik.

Verkehrssysteme bringen mehrere Herausforderungen mit sich: Verkehr ist ein multiskalen dynamisches System vieler heterogener Teilchen mit heterogenen, asymmetrischen Wechselwirkungen und - aufgrund der Tatsache, dass Verkehrsteilnehmer Entscheidungen treffen, die von ihren, jedem externen Beobachter verschlossenen, Zielen abhängen - unbekannten Bewegungsmodellen. Gerade Letzteres ist für eine Prädiktion der Situationsdynamik über längere Zeiträume problematisch, wie sie für einen vorausschauenden Fahrstil notwendig ist. Ferner beruhen die Messungen auf komplexen Kombinationen nichtlinearer Sensoren.

Existierende Perzeptionssysteme umgehen diese Probleme, indem sie approximative Bewegungsmodelle allein auf Basis der physikalischen Fahrdynamik nutzen und damit Wechselwirkungen mit der Verkehrssituation, und damit letztendlich dem Verkehrskontext, ignorieren. Letztere werden dann nachgelagert in der Kognitionsstufe behandelt. Deshalb ist jedoch eine Vorhersage der Verkehrssituation häufig nur über kurze Zeiträume möglich. Damit ergeben sich zwei Erweiterungsmöglichkeiten.

Zum einen ist es möglich, die Struktur der Bayesschen Zustandsschätzung zu übernehmen, die Zustandsvariablen explizit vorzugeben, Bewegungsmodell und Messmodell jedoch mittels Neuronaler Netzwerke aus Daten zu lernen [37] [38]. Somit wird Vorwissen über die Struktur des Zustandsraums und damit in der Struktur des Systems verankert. Einen solchen Ansatz verfolgen die Autoren in [39] sehr erfolgreich anhand der für die Fußgängererkennung wichtigen Pose-Estimation. Eine Erweiterung auf breite Anwendung im Bereich der Umweltperzeption ist daher vielversprechend. Damit ergibt sich die Möglichkeit, den Verkehrskontext in die Zustandsschätzung zu integrieren, und längerfristige Vorhersagen über die Verkehrsdynamik zu ermöglichen. Komplementär dazu kann man die Zustandsvariablen lernen [40] [41] [42]. Dieser Ansatz hat den

Vorteil, dass die dynamische Entwicklung des Systems in den gelernten Zustandsvariablen als linear bestimmt werden kann [43]. Damit transferiert man die bekannte, stabile Prädiktion linearer Bewegungsmodelle auf nichtlineare Systeme [38] [44]. Dies ist gerade im Hinblick auf die zur Pfadplanung wichtige Prädiktion der Trajektorien anderer Verkehrsteilnehmer essentiell.

3. Relationales und Logisches Wissen

Relationales oder logisches Wissen wird häufig in Form eines strukturierten Graphen repräsentiert. Klassische Vertreter dieser Darstellung sind Wissensdatenbanken oder Probabilistische Graphische Modelle (PGM). Typische Vertreter dieser Modellkategorie sind Bayesnetze [45] [46] [47]. Eine direkte Verarbeitung relationaler Information kann über Graph Neural Networks [48] [49], die das Prinzip des Deep Learning auf Graphen übertragen, erzielt werden. Neuronal-symbolische Systeme integrieren maschinelle Lern- und Schlussfolgerungsverfahren [50] [51] [52] [53]. Diese etablierten Methoden und Anwendungsansätze werden in diesem Projekt auf das autonome und vernetzte Fahren für Situationsinterpretation und logisch plausible und erklärbare Entscheidungen im Kontext von Wissen, wie z.B. Verkehrsregeln und Normen (situativ, ethisch, risiko-/werte-basiert), übertragen. Neuronal-symbolische Systeme bieten dabei den Vorteil der (semantischen) Erklärbarkeit, Modularität und Generalität indem sie logische Regeln mit Daten zum Lernen kombinieren, während sie gleichzeitig die Daten zur Feinabstimmung und Erklärung des Wissens nutzen. Damit werden zwei fundamentale kognitive Eigenschaften für die höhere Automatisierung von Fahrzeugen integriert: die Fähigkeit, aus Fahrzeug- und Umgebungsdaten automatisch zu lernen und die Fähigkeit, wissensbasierte semantische Schlussfolgerungen daraus abzuleiten [54].

3. Methoden zur Gewinnung von Wissen aus einer datengetriebenen KI-Funktion

Durch Deep Learning (DL) erzeugte Modelle zeigen zwar eine hohe funktionale Güte, erzeugen aber zunächst abstrakte Repräsentationen, aus denen keine erklärbaren Rückschlüsse in Bezug auf das Modellverhalten gezogen werden können. Damit ergeben sich massive Einschränkungen bzgl. systematischer Tests und der formalen Verifikation solcher Modelle.

Methoden der Wissensextraktion haben das Ziel, diese Einschränkungen zu beheben, wobei vor allem die folgenden Punkte relevant sind:

- Durch die Möglichkeit, Wissen aus durch DL erzeugten Modellen extrahieren zu können, steigen die Erklärbarkeit und Interpretierbarkeit dieser. Dies legt die Voraussetzung für die Plausibilisierung und Absicherung von KI-Funktionen, was vor allem eine Relevanz für sicherheitskritische Funktionen, wie jenen beim automatisierten Fahren, hat. Weiterhin kann extrahiertes Wissen zur Diagnose von maschinellen Lernverfahren eingesetzt werden. Zum Beispiel kann damit der Einfluss von verschiedenen Datensätzen auf die KI-Funktion evaluiert und der Einfluss der Modellarchitektur systematisch erfasst werden. Dadurch entsteht der Vorteil einer gezielten Parametrisierung von durch DL erzeugten Modellen und einer erhöhten Güte.
- Durch die Wissensgewinnung lässt sich die funktionale Güte neu erzeugter Modelle erhöhen. Dies ist vor allem wichtig, um mit möglichst wenigen Daten Modelle mit hoher Güte generieren zu können. Damit lassen sich auch Aufwände in der Datenerzeugung reduzieren und Wissen von einem zum anderen Modell übertragen. Dadurch können robustere und effizientere KI-Funktionen für das autonome Fahren entwickelt werden, insbesondere für selten auftretende kritische Fahrsituationen.

- Schließlich können ML-Modelle entwickelt werden, welche direkt aus Daten eine Vorhersage von Wissen erzeugen können. Dies spielt vor allem eine zentrale Rolle bei der Pfadplanung und Situationsanalyse beim autonomen Fahren.

Ein wichtiger Schritt bei der Entwicklung sicherheitskritischer Anwendungen im autonomen Fahren ist dabei die Extraktion von transparentem Wissen bzw. Konzepten aus den Modellen. Dabei existieren bereits unterschiedliche Ansätze und Methoden, welche als Grundlagen für die Entwicklung der relevanten Arbeiten in KI Wissen dienen sollen. Die folgenden Absätze geben einen Überblick über den aktuellen Stand der Technik.

1. Erklärbarkeit und Interpretierbarkeit

Ein verbreitetes Ziel vieler Algorithmen zum Erlernen von Datenrepräsentationen liegt darin, eine kompakte Darstellung der relevanten Information sowie eine Trennung der einzelnen Einflussfaktoren, sogenannte Disentangled Representations Verfahren [55], zu ermöglichen. Einzelne Attribute lassen sich somit idealerweise unabhängig voneinander betrachten, was wiederum die Interpretierbarkeit erhöht [56]. Um Wissen über den Funktionszusammenhang zwischen Eingangssignalen und Ausgangsgrößen zu erhalten, besteht eine Möglichkeit darin, die Informationsverarbeitung und den Entscheidungsprozess für den Menschen durch Methoden aus dem Bereich Explainable AI [57] erklärbar und interpretierbar zu machen.

Um verwendete Ansätze des maschinellen Lernens verstehen und dadurch verbessern zu können, ist eine Interpretation durch den Menschen unumgänglich. Hier setzt das Feld der Visual Analytics an [58], welches durch Interaktion Expertenwissen direkt mit in das Modell einbringt. Um die Transparenz des Trainings neuronaler Netze weiterhin zu erhöhen, werden die Methoden zur Inspektion und Analyse der Loss Surfaces erforscht. Ein besseres, strukturierteres Wissen über den Einfluss der Geometrie der Loss Surfaces, erhöht die Nachvollziehbarkeit der neuronalen Netze und des Aufbaus von Datensätzen.

Zur Fehlererklärung durch Wissensextraktion stehen etablierte Algorithmen zur Verfügung, welche jedoch nicht systematisch auf Perzeption im Straßenverkehr angewendet wurden. Zu diesen zählt das Verfahren der Saliency und Heat Maps [59], die es ermöglichen, die Teile des Inputbildes zu identifizieren, die für eine (Fehl-)Detektion verantwortlich sind. Um Probleme zu erkennen, deren Ursache in der Verteilung der Trainingsdaten liegt, werden moderne Algorithmen zur Dimensionsreduktion und Visualisierung angewandt, im Speziellen t-distributed Stochastic Neighbor Embedding (t-SNE) [60].

2. Wissensgewinnung

Die Verfahren, die unter dem Begriff der Rule Extraction [61] zusammengefasst werden, beschäftigen sich zum einen mit der Erklärbarkeit von nicht-transparenten Modellen, wie z.B. tiefen neuronalen Netzen, und zum anderen mit der Wissensextraktion.

Neuronal-symbolische Lerner [62] erlauben zusätzliches symbolisches Wissen direkt zum Lernen zu nutzen, so dass u.a. die im Allgemeinen niedrige funktionale Güte neuronaler Netze bei einer Extrapolation aus der Trainingsdomäne verbessert wird. Darüber hinaus ermöglicht die Integration von neuronalen und logikbasierten symbolischen Modellen, die Umfeldwahrnehmung eines AD-Fahrzeuges mit semantischem Wissen in Verbindung zu bringen.

Question & Answering (QA) beschreibt Verfahren, die auf der Basis von Daten (z.B. Bilder, Textdokumente) und einer natürlichsprachlichen Frage über die Datenrepräsentation eine natürlichsprachliche Antwort als Ausgabe erzeugen [63]. Zu diesem Zweck wird häufig auf Wissensdatenbanken zurückgegriffen, um Schlussfolgerungen und somit kontextbezogenes Wissen abzuleiten.

Auto-Encoder durchlaufen eine ähnlich erfolgreiche Entwicklung wie Neuronale Netze selbst. Sie haben sich als attraktive Möglichkeit zur Dimensionalitätsreduktion und Feature Extraktion erwiesen [64]. Durch die Restriktion auf eine niedrigere Dimension ist der Auto-Encoder gezwungen, sich auf die relevanten Aspekte in den Daten zu fokussieren und verdichtete Informationen und Wissen herauszustellen [65]. Die so entstehenden Abstraktionen stellen einen interessanten Ansatzpunkt für weitere Algorithmen und Analysen dar. Neben der Gruppe der Denoising Autoencoder (DAE) [66], die auf die Bereinigung von Störsignalen abzielen, sind insbesondere die Contractive Autoencoders (CAE) [67], die durch eine Regularisierung der Encoder-Funktion eine möglichst passende Repräsentation in niedrigerer Dimension anstreben, für das vorliegende Forschungsvorhaben von Interesse.

Um der Limitation der begrenzten Interpretierbarkeit Neuronaler Netze entgegenzuwirken, hat sich die Extraktion von Fuzzy Logik aus Neuronalen Netzen als spannendes Forschungsgebiet entwickelt [68] [69]. Fuzzy Logic kann zwar selten mit einer ähnlich hohen Güte wie die der Neuronalen Netzen aufwarten, bietet jedoch den Vorteil der leichteren Interpretierbarkeit [69]. Fuzzy Regeln sind deutlich näher an einer menschlichen Interpretation als die komplexen Beziehungen, wie sie sich in neuronalen Netzen wiederfinden. Fuzzy Rule Extraktion aus Neuronalen Netzen, bspw. mithilfe von evolutionären Algorithmen wie REX, hat bereits vielversprechende Ergebnisse in Form von einfach interpretierbaren Regeln zur Klassifikation geliefert [69]. Darüber hinaus wurde gezeigt, dass sich die Ansätze auch auf Regressionsprobleme übertragen lassen [68]. Da Fuzzy Logik bereits an verschiedenen Stellen in der Automobilindustrie und in der Steuerungstechnik zur Anwendung kommt, stellt dieser Ansatz eine vielversprechende Möglichkeit dar, die Blackbox-Algorithmen aus dem Bereich des autonomen Fahrens mit bekannten Techniken zugänglicher zu machen [70]. In einer neueren Veröffentlichung wurde außerdem gezeigt, wie sich mit Fuzzy Neural Networks, Spurwechsel vorhersagen lassen [71].

Markov Decision Logic (MDL) Netzwerke beschreiben Verfahren, die ein Gibbs/Markov Netz aus einer großen Anzahl direkt und indirekt beobachtbarer Zufallsvariablen aufbauen. Beziehungen zwischen diesen Variablen lassen sich als unscharfe strukturelle Regeln zwischen diesen Variablen formulieren. Dabei werden die strukturellen Regeln zwischen den Daten nicht nur bestmöglich eingehalten, sondern Regelverletzungen lassen sich explizit identifizieren [72] [73].

Reinforcement Learning (RL) bezeichnet eine Gruppe von Algorithmen, die durch das Prinzip von "Trial-and-Error"-Lernen bestimmte Aufgaben in einer dynamischen Umgebung lösen können. Mit der Erweiterung von klassischen RL-Ansätzen durch DL und tiefe neuronale Netze konnten schon vielversprechende Ergebnisse im Bereich des autonomen Fahrens erzielt werden [74]. Hierbei lässt sich durch Extraktion der gelernten Strategien neues Wissen erkennen [75].

Bayessche Netze (BNs) benutzen gerichtete azyklische Graphen zur kompakten Repräsentation hochdimensionaler Wahrscheinlichkeitsverteilung als Produkt lokaler Wahrscheinlichkeitsverteilungen [76]. Im Gegensatz zu Deep Neural Networks ist das in einem

Bayesschen Netz kodierte Wissen explizit durch die Graphstruktur und die Parameter der Wahrscheinlichkeitsverteilungen bereitgestellt und damit extrahierbar. Sie sind ein fester Bestandteil im Automotive-Bereich und finden entsprechend vielseitige Anwendung, z.B. zur Intentionserkennung [77] [78] und Prädiktion von Fahrzeugtrajektorien [79].

3. Vorhersagen von Wissen

Neuronale Modelle für Zeitreihen sind bisher stark fokussiert auf Modelle, die Zeitreihen möglichst exakt auf der Sensorebene erklären. Dabei treten mehrere Probleme auf: Bei höherdimensionalen Sensoren tendieren Modelle dazu, sich auf unwichtige Details (bspw. Hintergrundpixel) zu fokussieren, da diese verhältnismäßig leicht vorherzusagen sind. Dem Nutzer ist es nicht oder nur unter erheblichem Aufwand möglich, zu erkennen, auf welcher Basis bestimmte Vorhersagen getroffen wurden. Um dem entgegenzuwirken, wurden kürzlich die Grundprinzipien des Variational Auto-Encoders (VAE, [40]) auf Modelle für Zeitreihen übertragen [42] [41].

Erfolgreiche Anwendungen von maschinellen Lernverfahren basieren oft auf der Vorhersage einzelner Variablen, wie etwa die Klassifizierung eines Fußgängers. Viele reale Szenarien in Bereichen der Bilderkennung oder der Interpretation komplexer Fahrsituationen beziehen sich aber auf strukturierte Ausgabevariablen. Modelle zum Lernen solcher strukturierten Ausgaben aus Eingabebeispielen zu finden ist das Ziel der Structured Output Prediction [80]. Einige Arbeiten beschäftigen sich mit Problemen beim autonomen Fahren. In [81] wird ein strukturiertes Lernmodell für die Umgebungserkennung präsentiert und [82] nutzen ein strukturiertes Modell, um die Unsicherheit bei der Einschätzung zukünftiger Situationen zu repräsentieren.

Neben der Bild- und Tonverarbeitung hat auch die Analyse von Text und Schrift (Natural Language Processing (NLP) und Text Mining) durch den Einsatz von Deep Neural Networks in den letzten Jahren erhebliche Fortschritte erzielt [83]. In dem umfangreichen Forschungsgebiet von NLP und Text Mining sind im Kontext dieses Forschungsvorhabens insbesondere Verfahren interessant, die eine höhere Ebene der Abstraktion aus zugrundeliegenden Texten extrahieren können, wie es bspw. Text Summarization Ansätze ermöglichen [84]. Hier haben sich mit Sequence-to-Sequence Recurrent Neural Networks (RNN) [85] und Generative Adversarial Network (GAN) [86] spannende Ergebnisse erzielen lassen.

4. Methoden zur datenunabhängigen Validierung der Vorhersagen und Entscheidungen einer KI-Funktion

KI, insbesondere Deep Learning, sieht sich beim Einsatz in sicherheitskritischen Umfeldern (z.B. autonomes Fahren) vielen Herausforderungen gegenüber. Beispiele hierfür sind Generalisierungen von Training auf Realität, Existenz von adversarialen Beispielen sowie unklare Sensitivität von neuronalen Netzen gegen kontextuelle Einflüsse. Dies führt zur Notwendigkeit von Plausibilisierungsmaßnahmen. Mittels expliziter Verankerung von regelbasiertem Wissen in datengetriebener Software können Akzeptanz für funktionale Sicherheit sowie gesteigerte Dateneffizienz und Verständlichkeit für neuronale Netze erreicht werden.

Grundlegende und teilweise domänenspezifische Arbeiten indizieren ein Potential der Nutzung von Wissen in der Plausibilisierung und Absicherung KI-basierter Verfahren im autonomen Fahren:

Erste Ansätze zur Nachverarbeitung von Ausgaben Neuronaler Netze finden sich in der Literatur über die Verwendung von Ensemble-Techniken oder Alternativen dazu, die ebenfalls wieder gelernte Komponenten enthalten können, sogenannte „Mixture of Expert“-Modelle [87]. Aus der Domäne des autonomen Fahrens gibt es für den Einsatz von Mixture of Experts-Anwendungen zur Erkennung von Fußgängern [88], zum Szenenverständnis [89] oder zur Sensorfusion [90]. Diese Ansätze bieten jedoch keine wissensbasierte Plausibilisierung von gelernten Ausgaben, sondern stellen lediglich eine besondere Art der Verbesserung der Güte dar, die allerdings im Fall der „Mixture of Expert“-Ansätze in der Lage sind, zusätzliche und erweiternde Eingangsdaten für die Verbesserung mit heranzuziehen.

Darüber hinaus bieten Konzepte wie Bayesian Neural Networks (BNN), die konzeptionell in der Lage sind, Vorwissen mit einfließen zu lassen, Ansätze, dieses Wissen auch für die Plausibilisierung zu nutzen. In der Praxis lassen sich Bayesian Neural Networks aber nicht beliebig trainieren, wie dies bspw. für Convolutional Neural Network der Fall ist. Auch hier gibt es aber bereits erste Ansätze, wie ein effektives Training von BNNs realisiert werden könnte [91], auf die im Rahmen von KI-Wissen aufgebaut werden kann.

Im Design klassischer neuronaler Netze ist Vorwissen lediglich über die Konstruktion von Verlusttermen (Losses) im Überwachten Lernen oder die Belohnungsfunktion (reward function) in Anwendungen des Reinforcement Learning zu integrieren. Eine anschließende Plausibilisierung zur Inferenzzeit ist dann jedoch nicht mehr möglich, da der wahre Wert unbekannt ist. Analog zu Netzwerken, die physikalisches und mathematisches Wissen integrieren, lassen sich diese sogenannten Physics Guided Networks auch im Validierungsprozess einsetzen. Kürzlich wurde dies mit weiteren Netzen kombiniert, um auch die induzierte Unsicherheit zu schätzen [92].

Eine zusätzliche Herausforderung neuronaler Netze stellt die Tatsache dar, dass das Training neuronaler Netze bisher immer noch auf eine große Anzahl sorgfältig und korrekt gelabelter Daten angewiesen ist. Aber auch diese Label können Fehler enthalten oder aber auch uneindeutig oder mehrdeutig sein - je nachdem wie eine Szene interpretiert wird oder wer das Label erstellt hat, können am Beispiel einer semantischen Segmentierung einer Szene mehrere Klassen valide oder plausibel sein. Erste Arbeiten greifen dabei auf die Verwendung von latenten Variablen zurück, um so eine Abbildung der Mehrdeutigkeit zu erhalten [93].

Die passende Wahl der Trainings- und Testdaten ist eine ständige Herausforderung bei Fragestellungen aus Machine Learning und Deep Learning [94]. Häufig wird die Auswahl und Gestaltung des entsprechenden Datensatzes manuell durchgeführt und ist daher einer gewissen Willkür ausgeliefert [95]. So können sich über ungewöhnliche Situationen in den Datenbeständen auch Konzepte in die Deep Learning Modelle übertragen und später wieder aus diesen resultieren, die bestehendem Experten- und Weltwissen widersprechen oder sogar gegen physikalische Gesetzmäßigkeiten verstoßen. Es gibt daher ein aktives wissenschaftliches Bestreben, auch diesen Schritt der Modellentwicklung kontrolliert und automatisiert durchzuführen. Insbesondere wo enorme Mengen an Daten, die schwer menschlich auswertbar sind, verarbeitet werden, bieten sich Hilfssysteme an. In [96] wird bspw. ein auf Machine Learning basierter Ansatz vorgestellt, der bei der kontrollierten Aufbereitung von Trainingsbildern unterstützt und gleichzeitig Expertenwissen mit berücksichtigt.

Darüber hinaus wäre eine mögliche Lösung zur Plausibilisierung neuronaler Netze gegeben, wenn die interne Entscheidungsfindung zusätzlich zur Ausgabe einer Lösung auch die Entscheidungsfindung begründen würde: eine Sonderform des maschinellen Lernens, die auch als causal reasoning oder explainable AI bekannt ist [97]. Basis hierfür ist jedoch der Abgleich mit entsprechendem Welt- oder Expertenwissen. Das Zurückgreifen auf Vorwissen oder externe Wissensquellen zur Verbesserung der Modellqualität wird im Maschinellen Lernen auch als Informed Machine Learning bezeichnet [98]. Das Wissen liegt in verschiedensten Formen vor. Relevantes Wissen kann bspw. aus Simulationen folgen bzw. physikalisches Wissen sein [99] [100]. Es kann sich um a priori Wissen handeln, das in Form von Regeln oder Relationen in Wissensgraphen [101] vorliegt und zu unterschiedlicher Zeit, vor und nach dem Lernprozess, in das Modell integriert wird [102] [103]. Wissen kann so auch bspw. über physikalische Randbedingungen während des Lernprozesses in das System integriert werden [104].

So wurde bspw. in [105] die proper orthogonal decomposition (POD) auf die Daten angewendet, um Zusammenhänge und Limitierungen, welche sich aus physikalischen Gesetzen ableiten lassen, in die Daten einzubetten, um dann das Mapping zwischen der Eingabe und den Koeffizienten der POD zu lernen. Derart lassen sich die physikalischen Zusammenhänge und Limitierungen erhalten.

Die Autoren von [106] demonstrieren, wie Domänenwissen aus physikalischen Gesetzen genutzt werden kann, um die Architektur eines Deep Neural Networks zu erstellen und damit sowohl den Trainingsprozess effizienter als auch die Vorhersagekraft genauer zu machen.

In [107] wird vorgeschlagen, das Erstellen von stringenten Safety-Konzepten mit Hilfe von formaler Verifikation mit der Synthese von Monitoren zur Laufzeitüberwachung von KI-Komponenten zu kombinieren, um damit KI-Komponenten mit Sicherheitsgarantien zu erhalten.

Insgesamt ergeben sich also Potentiale in der Plausibilisierung durch Verwendung von zusätzlichen Eingangsdaten in Expertenmodellen, BNNs, physikalischen Modellen und Randbedingungen, Wissensgraphen, Monitoren und auch der Kombination unterschiedlicher Methoden, wobei auf zahlreiche Vorarbeiten zurückgegriffen werden kann, um diese auf die konkreten Anwendungsfälle der in diesem Vorhaben untersuchten Use Cases zu übertragen.

5. Demonstratoren mit wissensbasierten KI-Komponenten

Optimierungsansätze für KI-Methoden werden oftmals lediglich anhand der Einzelkomponenten und unter Anwendung allgemein anerkannter, aber nicht auf die konkrete Problemstellung angepasster Metriken durchgeführt. Dies führt teilweise zu Systemen, die hinsichtlich verschiedener Parameter optimiert sind, im Kontext eines Gesamtsystems aber nur eine untergeordnete Rolle spielen. Im ungünstigsten Fall zeigen die Optimierungsmaßnahmen im Rahmen der Integration in ein Gesamtsystem keine Auswirkung auf das Verhalten der übergeordneten Instanz, obwohl die Ergebnisse anhand der verbesserten Maßzahlen bei Betrachtung der einzelnen Komponente vielversprechend waren.

Als ein erster Schritt in der Perzeptionskette eines AD-Fahrzeugs wird oft die Objekterkennung in Bildern gesehen, d.h. es soll der Typ und die Position von Objekten in einem Bild bestimmt werden. Zur Bewertung entsprechender Verfahren wird oftmals Intersection over Union (IoU) als Gütemaß verwendet [108]. Hierbei wird die Überschneidung der prädizierten Bounding Boxes mit den korrekten Bounding Boxes auf einem Testdatensatz verglichen. Je besser eine prädizierte und

korrekte Bounding Box überlappen, desto besser wird der Algorithmus bewertet. Hierbei wird aber bspw. völlig ignoriert, wie weit ein Objekt zum Fahrzeug entfernt ist. Da weit entfernte Objekte in einem Bild naturgemäß sehr klein und dementsprechend nur durch wenige Pixel dargestellt sind, ist für diese Objekte der Fehler in den Vorhersagen tendenziell größer.

Für die sichere Bewältigung der Fahraufgabe durch ein AD-Fahrzeug sind aber eher nahe Objekte von Interesse, anstatt der noch weit entfernten. Daher ist eine gleich starke Bestrafung von Fehlern für nahe und entfernte Objekte tendenziell nicht sinnvoll. Diese Beobachtung hat auch die Entwickler des nuScenes-Datensatzes dazu bewogen, bei der Entwicklung der nusenes Dataset Score (NDS) weiter entfernte Objekte in der Evaluierung auszuklammern [109]. Auch das Wissen darüber, dass die korrekte Bestimmung der Orientierung von Objekten wichtig ist, wurde in die NDS-Metrik als auch die Mean average precision weighted by heading (mAPH) Metrik [110] mit eingebunden.

Durch Experten kann also eine Metrik kreiert werden, die unterschiedlichste Aspekte mit in Betracht ziehen kann. Es ist jedoch schwierig, alle Aspekte zu finden, adäquat in der Metrik abzubilden und dann eine geeignete Gewichtung dieser verschiedenen Aspekte zu definieren. Diese Beobachtung konnte auch in [111] gemacht werden, sodass hier ein neuer Ansatz gewählt wurde. Anstatt die Bewertung anhand der direkten Vorhersagen des Modells vorzunehmen, wurde hier der Effekt der Vorhersagen auf die Plan-Komponente des AD-Fahrzeugs betrachtet, die durch das Training auf einem Datensatz erstellt wurde. Mit der Plan-Komponente kann der Unterschied gemessen werden, wie unterschiedlich sich das AD-Fahrzeug verhalten würde, wenn es die prädizierten Objekte sehen würde, anstatt der echten Objekte. Die Autoren konnten in ihren Experimenten zeigen, dass durch diesen Ansatz automatisch Abweichungen in der Orientierung bestraft wurden, ohne dies explizit festzulegen.

Es lässt sich also ein Trend erkennen, die Teilkomponenten nicht nur einzeln, sondern auch im Kontext eines Teilsystems oder Gesamtsystems zu bewerten. Hierfür sind neben Bewertungsmetriken auch eine Testumgebung und die Testbedingungen festzulegen. Weltweit sind sowohl die Industrie (OEM und Tier1) und auch die Zulassungsautoritäten auf der Suche nach sinnvollen Kriterien, um die funktionale Zulassungsfähigkeit von autonomen Fahrzeugen feststellen zu können. Unter anderem spielen hierbei sowohl Bewertungsmetriken als auch Szenarienkataloge für das Abfahren von Tests eine wichtige Rolle.

Hierfür werden in Industrie und Wissenschaft offene Standardisierungsformate vorangetrieben, um entsprechende Gesamtsysteme testen zu können. OpenDRIVE [112] ist ein Kartenformat, in dem Straßennetzwerke logisch beschrieben werden können. Mit Hilfe von OpenSCENARIO [113] kann dann dynamisches Verhalten für die Ausführung einer Simulation spezifiziert werden. Eine für dieses Vorhaben interessante, quelloffene Simulationsumgebung ist CARLA, da sie für die besonderen Erfordernisse der Entwicklung, des Trainings von KI-Funktionen und ihrer Validierung auf dem Gebiet des autonomen Fahrens im urbanen Umfeld entwickelt wurde. Um verkehrliches Verhalten auf einer makroskopischen Ebene simulieren und bewerten zu können, eignen sich Verhaltenssimulationen wie SUMO [114] oder Menge [115]. Durch offene Protokolle oder die Unterstützung von Softwarebibliothekensammlungen, wie z.B. das Robot Operating System (ROS) [116], können Simulationen auch aneinander angebunden werden.

Bei der Festlegung von Szenarienkatalogen gibt es weltweit verschiedene Projekte, welche sich direkt oder indirekt mit dem Testen eines Gesamtsystems befassen, z.B. die Datenbank des PEGASUS-Projekts [117], MUSICC [118], CARLA Scenarios [119], KI Absicherung).

Die Verwendung dieser offenen Standards, Tools und Szenarienkataloge könnte somit eine Bewertung von entwickelten Verfahren im Kontext eines Gesamtsystems ermöglichen, welche in der Literatur bisher noch keine große Bedeutung gefunden hat.

6. Offene Fragestellungen und Fortschritt gegenüber dem Stand der Technik

Auf Basis des beschriebenen Stands der Wissenschaft und Technik ergeben sich offene Fragestellungen, die einem breiten Einsatz der KI-Funktionen im Kontext des autonomen Fahrens derzeit im Wege stehen. Im Folgenden werden die offenen Fragestellungen anhand der sechs Projektziele aufgezeigt und der Beitrag des Vorhabens KI Wissen zur Lösung dieser Herausforderungen beschrieben. Diese offenen Fragestellungen auf Ebene der Projektziele schlagen sich entsprechend auf die Kerninnovationen und somit auf die Arbeiten in den verschiedenen Teilprojekten und Arbeitspaketen nieder.

1. Gültigkeitsbereich

Für sich im autonomen Fahren ergebende Gefahrensituationen ist das Einfahren realistischer Trainingsdaten aufgrund von ethischen Gründen nicht möglich. Vor allem diese Gefahrensituationen sollen aber ebenfalls durch KI-basierte Methoden beherrscht werden können. Zudem sollen bestehende Techniken erweitert werden, indem physikalische Bedingungen, die sich aus komplexen Verkehrssituationen ergeben, in bestehende KI-Architekturen integriert werden. Damit würde sich zum einen der Aufwand bei der Datenerzeugung verringern lassen, aber insbesondere würde sich der Gültigkeitsbereich der trainierten KI auf jene Situationen erweitern, für die bislang keine oder nur unzureichend viele Trainingsdaten vorlagen.

Ein wesentlicher Beitrag von KI Wissen beim Erweitern des Gültigkeitsbereiches eines neuronalen Netzes neben der Berücksichtigung physikalischer Gesetzmäßigkeiten ist allerdings die Integration von bestehendem Wissen, welches sich nicht durch Sensoren etc. messen lässt. Dieses sogenannte Weltwissen muss zunächst geeignet formalisiert und anschließend in den Trainingsprozess integriert werden. Eine der wichtigsten offenen Fragen ist daher, wie dieses Wissen der KI zur Verfügung gestellt werden kann, um die für autonomes Fahren notwendige funktionale Güte bei der Vorhersage der Verkehrssituationen zu gewährleisten und mit den begrenzten Daten dennoch Modelle mit hoher Güte trainieren zu können, sodass insbesondere für kritische, unterrepräsentierte Verkehrssituationen der Gültigkeitsbereich der KI erweitert und somit sicheres Fahren ermöglicht werden kann. Die neuronal-symbolische Integration hat eine seit mehreren Jahren aktive Forschungs-Community, deren etablierte Methoden und Anwendungsansätze in diesem Forschungsprojekt auf das autonome und vernetzte Fahren für Situationsinterpretation und logisch-plausible und erklärbare Entscheidungen im Kontext von Wissen, wie z.B. Verkehrsregeln und Normen (situativ, ethisch, risiko-/wertebasiert), übertragen und erweitert werden.

2. Robustheit

Es existieren zwar bereits wissensbasierte Ansätze zur Erhöhung der Robustheit einer KI, jedoch bleibt offen, wie kritische, selten auftretende Verkehrssituationen ohne entsprechende

Datengrundlage, sondern allein durch die Einbeziehung relevanten Wissens aus verschiedenen Wissensquellen, von einem autonom fahrenden Fahrzeug gemeistert werden können. Darüber hinaus soll auch in untypischen Situationen, die nicht zwangsläufig kritisch, aber so ungewöhnlich sind, dass sie sich nicht in den Trainingsdaten finden, eine sinnvolle Planung von Manövern gewährleistet sein.

In diesem Zusammenhang ergeben sich offene Fragestellungen und Herausforderungen hinsichtlich der Heterogenität der zu untersuchenden Wissensquellen (Expertenwissen, mathematische Zusammenhänge etc.). Neben der Wechselwirkung einzelner Wissensbestandteile soll die Integration von zusätzlichem Wissen in bestehende Systeme die Performanz in unkritischen Szenarien möglichst nicht beeinträchtigen.

3. Kosten- / Zeitersparnis

In KI Wissen sollen die bestehenden wissensbasierten Ansätze erweitert werden, indem das Wissen aus verschiedensten Wissensquellen einer KI zugänglich gemacht wird. Damit soll die Anzahl der benötigten annotierten Daten deutlich verringert werden, andererseits auch synthetische und damit wesentlich kostengünstiger zu gewinnende Daten verstärkt in das Training der KI Einzug finden. Darüber hinaus ist noch nicht klar, wie aus einer KI extrahiertes Wissen verwendet werden kann, um sinnvoll auf neue Situationen zu reagieren. Auch dies soll ein Beitrag von KI Wissen sein und zu einer weiteren Reduzierung der erforderlichen Daten und Annotationen beitragen.

Offene Fragestellung in diesem Projekt ist, wie neuronal-symbolische Lernansätze genutzt werden können, um zusätzliches verkehrliches Wissen direkt zum Lernen zu nutzen, so dass u.a. die Schwierigkeiten mit der Extrapolation bei neuronalen Netzen verbessert werden. Darüber hinaus soll die neuronal-symbolische Integration von neuronalen Modellen mit logikbasierten symbolischen Modellen ein integriert lernendes KI-System ermöglichen, das Informationsverarbeitung auf niedrigerer Ebene (zur Wahrnehmung und Mustererkennung aus den Fahrzeug- und Umgebungsdaten) mit übergeordnetem abstrakten/semantischen Wissen (zur wissensbasierten Schlussfolgerung, logisch plausiblen Begründung und semantischen Erklärung, z.B. über nicht-monotone Inferenz bei Ausnahmen) in Verbindung bringt.

4. Nachvollziehbarkeit

Die aktuellen Methoden aus dem Bereich des Explainable AI reichen noch nicht aus, um herauszufinden, welche Verkehrssituationen zu welchen Reaktionen eines KI-gesteuerten Fahrzeugs führen, um damit das Systemverhalten basierend auf den Präferenzen der Insassen verbessern zu können. Es ist zu prüfen, ob zusätzlich in den Trainingsprozess integriertes Wissen unterschiedlicher Wissensquellen eine Verbesserung der Interpretierbarkeit und Erklärbarkeit der Vorhersagen liefert und ob sich dadurch neues Wissen besser ableiten lässt.

Offene Fragestellung ist die Umsetzung von zwei fundamentalen kognitiven Eigenschaften für die höhere Automatisierung von Fahrzeugen. Dies integriert die Fähigkeit, aus Fahrzeug- und Umgebungsdaten automatisch zu lernen und die Fähigkeit, wissensbasierte semantische Schlussfolgerungen daraus abzuleiten.

Fragestellungen ergeben sich außerdem hinsichtlich geeigneter Repräsentationsformen und der Abwägung vom Einsatz maschinenlesbarer Darstellungen, die oftmals eine gute Performanz aber

geringe Erklärbarkeit aufweisen, und vom Menschen interpretierbarer Merkmale, die bei erhöhter Nachvollziehbarkeit die Systemleistung negativ beeinflussen können.

5. Zuverlässigkeit

Ein problematischer Aspekt ist die Auswahl der Trainings- und Testdaten [94], die oft manuell durchgeführt und daher einer gewissen Willkür ausgeliefert ist [95]. Allerdings können sich ungewöhnliche Situationen in den Daten auf die Vorhersagen der KI übertragen und so zu physikalisch inkonsistenten Vorhersagen führen. Das Ziel ist, bestehende Ansätze dahingehend zu erweitern, dass insbesondere auch in seltenen und kritischen Verkehrssituationen Vorhersagen getroffen werden, welche mit bestehendem Wissen konform sind. Dabei liegt der Fokus nicht allein auf physikalischen Gesetzmäßigkeiten, sondern auch auf Welt- und Expertenwissen, d.h. die Vorhersagen sollen konsistent mit bestehenden (Verkehrs-)Regeln sein. Die offene Fragestellung ist, wie diese vorhandenen Verkehrsregeln und Normen in neuronal-symbolischen Ansätzen mit adäquater semantischer Ausdrucksmächtigkeit repräsentiert und genutzt werden können.

6. Nutzen

Die Evaluierung eines Gesamtsystems, welches sämtliche Komponenten aggregiert, erfordert die gemeinsame Festlegung auf wenige Use Cases und Metriken zur Analyse. Es ist daher essentiell für die Bewertung der im Rahmen dieses Projekts erzielten Ergebnisse, die Teilkomponenten sowohl einzeln als auch im Kontext eines Gesamtsystems zu bewerten. Zur Evaluierung von Teilsystemen und auch eines Gesamtsystems sind neben Bewertungsmetriken auch eine Testumgebung und die Testbedingungen festzulegen. Weltweit sind sowohl die Industrie (OEMs und Tier1s) und auch die Zulassungsbehörden auf der Suche nach sinnvollen Kriterien, um die funktionale Zulassungsfähigkeit von autonomen Fahrzeugen feststellen zu können. Unter anderem spielen hierbei sowohl Bewertungsmetriken als auch Szenarienkataloge für das Abfahren von Tests eine wichtige Rolle.

Die offene Fragestellung ist, wie die neuronal-symbolische Integration von neuronalen Modellen mit logikbasierten symbolischen Modellen ein integriert lernendes KI-System ermöglicht, das Informationsverarbeitung auf niedrigerer Ebene (zur Wahrnehmung und Mustererkennung aus den Fahrzeug- und Umgebungsdaten) mit übergeordnetem abstrakten/semantischen Wissen (zur wissensbasierten Schlussfolgerung, logisch plausiblen Begründung und semantischen Erklärung z.B. über nicht-monotone Inferenz bei Ausnahmen) in Verbindung bringt.

7. Neuheit im Vergleich zu laufenden Aktivitäten

Das Projekt KI Wissen verfolgt einen neuartigen Ansatz im Bereich der künstlichen Intelligenz für autonomes Fahren. Sind bislang die Projekte in der deutschen Forschungslandschaft eher auf die Aneignung und Absicherung von KI mittels Daten ausgerichtet, soll in diesem Vorhaben die Anreicherung und Verfügbarmachung von Wissen für die KI mittels Kombination aus Daten und bekanntem a priori Wissen, wie Regeln und Abhängigkeiten von physikalischen und anderen Gesetzmäßigkeiten, im Vordergrund stehen. Hierbei handelt es sich um faktisches und normatives Wissen, das in zahlreichen Formen und Ausprägungen zur Verfügung steht. So kann die KI für verkehrstechnisch relevante Anwendungen generalisiert werden, für die nur wenige oder keine Daten zur Verfügung stehen.

In der Aufnahme des a priori Wissens in die Trainingsprozesse der KI steckt das Potential, die benötigte Rechenleistung und die benötigte Datenmenge für den Anwendungsfall autonomes Fahren drastisch zu senken. Um eine Erhöhung der Stabilität der trainierten KI auf Störungen innerhalb der Daten zu realisieren, kann solches Wissen in extrahierter Form flexibel, modular und universell in verschiedenen Trainingsverfahren eingesetzt werden. So kann gleichzeitig eine Steigerung der Erklärbarkeit durch Regeln, der Absicherbarkeit und der Diagnose von Vorhersagen der KI stattfinden. In der Folge kommt es auch zu einer klareren Detektion von Inkonsistenzen der trainierten KI im Vergleich zum existierenden a priori Wissen.

Im Kontext des Gesamtsystems verspricht die Einbindung von vorhandenem a priori Wissen und die Extraktion des Output-Wissens eine Optimierung der Effektivität der verwendeten Technologie. Auf diese Art wird die deutsche Automobilindustrie von dieser Effektivitätssteigerung Nutzen ziehen und kann eine Vorreiterrolle bei der effizienten Nutzung von Rechenleistung, Trainingsdauer und -aufwand von KI einnehmen.

In anderen Bereichen der Industrie gibt es bereits vereinzelt Systeme, in denen existierendes Wissen für KI verfügbar gemacht wird. Im Verkehrssektor beispielsweise sind einige prominente Anwendungsfälle bekannt:

- Heuristiken zur Optimierung der Route, Kartenmaterial für Navigationssysteme und teilweise Extraktion von Baustelleninformationen zur Anreicherung des Optimierungsproblems
- In der Stauvorhersage wurden sowohl physikalische Modelle aus Herdenbewegungen als auch Diffusionsgesetze zur Vorhersage von Stauentwicklung und extrahierte Bewegungsmuster aus Mobilfunkdaten eingesetzt
- A priori Wissen (Regeln, einfache physikalische Zusammenhänge, etc.) wird aktuell in der Programmierung von Steuergeräten bspw. von Hybridmotoren oder dem ABS eingesetzt
- Die Identifizierung von Personen im Umfeld auf Basis von Radardaten wird in Hardware-komponenten aktuell fast ausschließlich über geometrisches und/oder physikalisches Wissen gewährleistet

Auch im Technologiesektor abseits des Verkehrssektors gibt es zahlreiche Beispiele, wie a priori Wissen den KI-Rechenaufwand minimieren und somit effizient gestalten kann:

- Gerade bei speziellen Rückfragen werden die Interaktion und Dialogführung in Question-Answering und Dialogue-Systemen über eine Kombination von a priori Wissen und Machine Learning gewährleistet
- In der Rekonstruktion von 3D-Objekten aus Bildern werden sowohl Machine Learning-Algorithmen eingesetzt als auch physikalisches und geometrisches Wissen
- Im Natural Language Processing führt sprachspezifisches Wissen in der Vorverarbeitung von Texten zur Übersetzung, zur Summarization, zur Informationsextraktion und zur Texterzeugung zu erheblicher Performance Steigerung
- In Vorschlagsystemen steigert die Integration von Weltwissen in Form von DB-Pedia Wissensgraphen die Trefferquote und das eigentliche Ranking gegenüber ausschließlich daten-getrieben Ansätzen

Das Projekt KI Wissen setzt auf diesen vorhandenen Arbeiten auf und entwickelt weitere, vielversprechende Ansätze speziell für den Bereich der Verkehrssysteme.

8. Bezug zu aktuellen Forschungsprojekten

Mit dem Vorhaben KI Wissen wurden erstmalig Methoden für die Einbindung verschiedener Arten von Wissen in das maschinelle Lernen in der Breite erforscht und der Proof-of-concept, sowohl der Methoden im Einzelnen als auch in deren Zusammenspiel, erbracht. Abbildung 7 zeigt die Beteiligung der Konsortialpartner an den Forschungsvorhaben, die einen inhaltlichen Bezug zu KI Wissen vorweisen.

Projekt	A. Thamm	Altran	AVL	BAST	Bosch	BTC	Continental	DFKI	DLR	EFS	FhG	fortiss	FZI	OFFIS	U Saarland	Valeo
3F																
ADAS&me																
AutoConstruct																
Cloud LSVA																
DefuseNN																
EVA-Shuttle																
IMAGinE																
KI Absicherung																
KI Data Tooling																
KI Delta Learning																
KI Plattform Konzept																
LiDARshared																
PEGASUS																
Providentia																
Providentia++																
SETLevel4to5																
UNICARagil																
VVMethoden																

Abbildung 7: Beteiligung der Konsortialpartner an den identifizierten Forschungsvorhaben mit inhaltlichem Bezug zu KI Wissen

1. ADAS&me

1. Beschreibung

Ziel der Forschungsinitiative ADAS&me ist die Adaption von Fahrerassistenzsystemen auf Fahrerzustand und den Umgebungskontext sowie die Berücksichtigung von dynamischem Kontrolltransfer zwischen Fahrer und Fahrzeug. Durch diese Ansätze soll die Sicherheit und Effizienz der Fahrerassistenzsysteme gesteigert werden.

Basierend auf sieben vorläufig identifizierten Use Cases für Automobile, Lkw, Busse und Motorradfahrer werden hierzu neue Algorithmen zur Zustands- und Situationserkennung erforscht, welche es erlauben, die Gesamtsituation zu erfassen. Diese Zustandsbeschreibung beinhaltet Informationen über den Fahrerzustand wie Müdigkeit, Aufmerksamkeit, Stress oder ablenkende Emotionen sowie Umgebungsinformationen wie Wetterbedingungen. Mit diesen Informationen können nun effektive, multi-modale und adaptive Vorwarnstrategien entwickelt werden.

Das Ziel des Projekts ist eine Fusion aller entwickelten Elemente in ein Zustandsüberwachungssystem, welches über das gesamte Spektrum der Automationsgrade genutzt werden kann.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

Das Projekt ADAS&me weist eine Reihe von Bezügen zum Projekt KI Absicherung auf, einem der Schwesterprojekte von KI Wissen aus der KI-Projektfamilie des VDA. Die in ADAS&me entwickelte Situationserkennung wird auch im Rahmen der KI Absicherung benötigt, um Corner Cases, in denen der Rückfall auf eine a priori existierende Wissens Ebene hilfreich ist, exakt spezifizieren zu können. KI Wissen plant eine enge Zusammenarbeit und einen Austausch von Ergebnissen mit KI Absicherung. Die Erkenntnisse des Projektes ADAS&me sind für KI Wissen zum einen aus diesem Grund interessant. Ein weiterer Anknüpfungspunkt besteht im Folgenden: Die Datenerfassung und Korrelation stellten im Projekt ADAS&me eine große Herausforderung dar. Aus den bereits in der Gesamtzielsetzung beschriebenen Gründen konnte nicht von einer weitreichenden Datenbasis ausgegangen werden. KI Wissen kann auf Erfahrungen aus ADAS&me aufsetzen und durch die Entwicklung von wissensbasierten Methoden zur Lösung des „Datenproblems“ beitragen, denn gerade im Bereich der Fusion mehrerer Eingabezustände ist die Einbindung von Wissen über die Wechselwirkung und Korrelation verschiedener Inputs äußerst vielversprechend.

2. Cloud LSVA

1. Beschreibung

Ziel des Cloud LSVA Projekts ist es, eine Softwareplattform in einer Cloud zu erstellen, um die große Menge an gelabelten Daten, die von KI-Methoden benötigt werden, bereitzustellen. Dort sollen die riesigen Datenmengen in einem weitestgehend automatisierten Prozess gelabelt und verbreitet werden. Somit können menschengemachte Annotierungen, die langsam, inkonsistent und teuer sind, vermieden werden. Die so erzeugten Datensätze sollen verwendet werden um Algorithmen zur echtzeitfähigen Verarbeitung von Sensordaten in Fahrzeugen zu trainieren und zu evaluieren. Dabei stehen die beiden Szenarien Advanced Driver Assistance Systems und Digital Cartography im Fokus.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

Im Rahmen von Cloud LSVA sollen ebenfalls Methoden des maschinellen Lernens zum Einsatz kommen. Im Gegensatz zu KI Wissen wird jedoch die Einbindung verschiedener Arten von Wissen in diese Methoden nicht beachtet. Anders als in KI Wissen liegt der Schwerpunkt in der Aufnahme und Annotierung von Daten. Die sogenannte Cloud LSVA Open Group ermöglicht den Datenaustausch an Nicht-Projekt-Beteiligte, weshalb die Nutzung dieser Daten für KI Wissen möglich ist. Die Sinnhaftigkeit dieser Nutzung muss im Bedarfsfall geprüft werden.

3. KI Absicherung

1. Beschreibung

Das Verbundprojekt KI Absicherung ist Teil der KI-Projektfamilie. Ziel des Projekts KI Absicherung ist die Entwicklung und Untersuchung von Methoden und Maßnahmen für die Absicherung KI-basierter Funktionen bzw. Einzelmodulen für das automatisierte Fahren. Hierfür soll der derzeitige Stand der Technik aufgegriffen und soweit vorangetrieben werden, dass erstmals ein gangbarer und im Expertenkreis anerkannter Weg hinsichtlich der prinzipiellen Herangehensweise zum Nachweis der Absicherbarkeit von KI-Modulen aufgezeigt wird.

Die Inhalte des Vorhabens sollen an einem definierten abgrenzbaren Use Case erarbeitet werden. Hierfür wurde die Fußgängererkennung aufgrund der sicherheitstechnischen Relevanz von „schwächeren“ Verkehrsteilnehmern ausgewählt. Es werden Methoden und Maßnahmen entwickelt, welche die Absicherung von KI-Funktionen sicherstellen können. Für den Beispiel-Use Case wird exemplarisch eine gesamtheitliche Argumentation für die Absicherung und deren Validierung definiert und umgesetzt.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

KI Wissen betrachtet ebenso wie KI Absicherung den Use Case der multisensoriellen Fußgängererkennung. Jedoch greift das Projekt KI Absicherung bei der Methodenentwicklung insbesondere auf statistische Verfahren zurück. Die Nutzung von Wissen als neuartige Methode ist hier nicht Schwerpunkt. Auch in KI Wissen werden Sicherheitsanforderungen und Nachweismethoden zur Absicherung KI-basierter Funktionen entwickelt, allerdings mit dem Schwerpunkt, dass zur Absicherung keine statistischen Verfahren sondern gelerntes oder bereits bekanntes Wissen verwendet wird. Die beiden Projekte sind daher komplementär und ergänzen sich methodisch in der Verfolgung einer gemeinsamen (Teil-)Zielsetzung.

Durch den im Vergleich zu KI Absicherung späteren Start des Vorhabens KI Wissen, kann KI Wissen Funktionen, Daten und Corner Case Definitionen übernehmen und weiterentwickeln. Die in KI Absicherung entwickelte Ontologie zur Beschreibung der Daten, der Absicherungsfunktionen und der Kategorisierung der Störfaktoren kann beispielsweise als Weltwissen in die Methoden von KI Wissen einfließen. Das von KI Absicherung entwickelte Sicherheitskonzept und die Teststrategie können in KI Wissen übernommen und anhand der hier entwickelten Methoden verifiziert und ausgebaut werden.

Weitere mögliche Anknüpfungspunkte sind die Verwendung der Kennzahlen und Daten aus KI Absicherung in KI Wissen sowie die Nutzung von wissensbasierten Methoden aus KI Wissen in der Absicherungsargumentation von KI Absicherung. Die Konsortien beider Projekte haben große Überschneidungen und bereits seit der Vorbereitungsphase gibt es enge Kontakte zur Vorbereitung einer Zusammenarbeit.

4. KI Data Tooling

1. Beschreibung

Das Verbundprojekt KI Data Tooling ist Teil der KI-Projektfamilie (siehe Kapitel 0). KI Data Tooling entwickelt Methoden und Tools, die eine Beschreibung, Verarbeitung, Selektion, Generierung, Komprimierung und Bereitstellung oder Übertragung von Daten ermöglichen. Ziel ist es, eine

Datenbasis für das Training, die Validierung sowie für Test und Absicherung von KI-Systemen herzustellen. Dabei werden Lösungen erzeugt, die es ermöglichen, effizient und systematisch Daten unterschiedlicher Güte, unterschiedlichen Ursprungs (Realdaten, synthetisch erzeugte Daten sowie deren Kombinationen), unterschiedlicher Sensorsetups oder -technologien zu nutzen und weiter zu verwerten.

Um die im Projekt entwickelten Methoden und Tools zu verifizieren, werden sie am Beispiel des Use Cases Fußgängererkennung verwendet und optimiert.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

KI Data Tooling beschäftigt sich speziell mit der Bereitstellung einer breiten Datenbasis für das Training, die Validierung sowie für Test und Absicherung von KI-Systemen. KI Wissen konzentriert sich auf die Entwicklung von Methoden für den Einsatz von Wissen im maschinellen Lernen und hat sich zum Ziel gesetzt, datenbasierte KI-Verfahren und wissensbasierte Methoden zusammenzubringen. Beide Projekte sind von ihrem Fokus her orthogonal und ergänzend und können von einer Kooperation profitieren. Die in KI Data Tooling erzeugten Daten und entwickelten Methoden sind für KI Wissen interessant. Von den in KI Wissen erarbeiteten Erkenntnissen, wie Daten und Wissen auf effiziente Weise kombiniert und welche Daten durch Wissen (nicht) ersetzt werden können, wird das KI Data Tooling-Projekt profitieren. Beide Projekte betrachten den Use Case der Fußgängererkennung. Zu diesen Aspekten ist eine enge Zusammenarbeit sehr sinnvoll. Die Konsortien beider Projekte haben große Überschneidungen und bereits in der Vorbereitungsphase beider Projekte gibt es enge Kontakte zur Vorbereitung einer Zusammenarbeit.

5. KI Delta Learning

1. Beschreibung

Das Projekt KI Delta Learning aus der KI-Projektfamilie beschäftigt sich mit dem Umgang von KI-Systemen unter sich verändernden Bedingungen, wie z.B. Einsatzorte, Sensoren oder Wetterbedingungen. In solchen Fällen müssen aktuelle Methoden des Maschinellen Lernens oftmals unter hohem Aufwand und Kosten neu trainiert werden. KI Delta Learning versucht diesen Aufwand zu verringern. Der Begriff „Delta“ beschreibt dabei die Differenz eines Ursprungssystems zum Zielsystem. Im Laufe des Projekts werden verschiedene Deltas betrachtet, wie das Delta zwischen aktuellen KI-Ansätzen und den Automotive-Anforderungen, das Delta zwischen einer bisher trainierten und neuen Domäne und das Delta verschiedener Lernstrategien.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

Das Projekt KI Delta Learning beschäftigt sich ebenfalls mit KI-Methoden und maschinellem Lernen, jedoch sind dort Verfahren basierend auf a priori Wissen explizit ausgeklammert. Dennoch wird im Rahmen des Deltas verschiedener Lernstrategien auch eine Transferierung von Expertenwissen eines komplexen neuronalen Netzes in ein kleineres, aber dafür echtzeitfähiges Netz untersucht. Allerdings wird hier Wissen als Fähigkeit zum Lösen eines konkreten Problems z.B. der Objektdetektion verstanden, nicht aber als physikalischer Zusammenhang oder komplexes soziales Normengefüge. Ein weiterer Berührungspunkt der beiden Projekte ist die Nutzung und Erzeugung synthetischer und realer Daten. Vor allem die Ergebnisse bezüglich des Deltas zwischen synthetischen und realen Daten können dabei für KI Wissen beachtenswert sein.

6. Providentia++

1. Beschreibung

Nach erfolgreicher Machbarkeitsstudie im Vorgängerprojekt Providentia, ist die Zielsetzung des Projekts Providentia++ der Aufbau eines Gesamtsystems zur kooperativen Umgebungswahrnehmung im Echtzeitbetrieb im Zusammenspiel von intelligenter Infrastruktur und autonomen Fahrzeugen. Im Fokus steht dabei eine robuste Perzeption von Verkehrsteilnehmern sowie eine Fusion aller erhobenen Informationen bei gleichzeitiger hoher Verfügbarkeit, d.h. selbst bei variierenden Verkehrssituationen (Autobahn, Stadtverkehr, Stau) und Einsatzbedingungen (Wettereinflüsse, Kommunikationsstörungen). Die angestrebten Beiträge zum Gesamtsystem sollen somit die Verkehrssicherheit erhöhen, effiziente Mobilität fördern und gesellschaftliche Potentiale des autonomen und vernetzten Fahrens heben. Herausforderungen ergeben sich hierbei in der dynamischen Selbstorganisation großer Sensorsysteme, sodass jederzeit eine verlässliche Aussage über das aktuelle Verkehrsgeschehen getroffen werden kann.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

Um eine hohe Verfügbarkeit zu gewährleisten, werden ebenfalls Problemstellungen wie die Auflösung von Verdeckungen, die robuste Prädiktion von Trajektorien zur Standortbestimmung und die Robustheit gegenüber Wetteränderungen betrachtet. Zu diesem Zweck sollen Informationen von allen Sensoren (extern über Schilderbrücken und Masten, sowie intern über interne Sensoren des Fahrzeugs) in geeigneter Weise fusioniert und als Hauptinformation in datengetriebene Modelle mit einfließen. Daraus resultierend ergeben sich sub-symbolische Systeme, die auf die Verarbeitung von multimodalen Sensordaten ausgerichtet sind. Eine explizite Integration von formalisiertem Expertenwissen oder physikalischen und mathematischen Gesetzmäßigkeiten steht allerdings nicht im Fokus.

Anknüpfungspunkte ergeben sich hinsichtlich der Zielsetzung, ein Gesamtsystem zu entwickeln und auf seine Machbarkeit zu überprüfen und als Resultat die entwickelte Infrastruktur zur Gewinnung von Daten zu nutzen, die die Entwicklung der Verhaltenssteuerung autonomer Fahrzeuge erheblich beschleunigen kann.

7. UNICARagil

1. Beschreibung

UNICARagil hat das Ziel, ein neues modulares und skalierbares Fahrzeugkonzept zu entwickeln, welches für diverse Anwendungsfälle des autonomen Fahrens wie privaten und öffentlichen Personentransport oder Gütertransport geeignet ist. Dieses ist untergliedert in eine funktionale Fahrzeugarchitektur und die Vernetzung dieser mit Infrastruktur, der Cloud und einer Sensordrohne. Die Entwicklungsziele umfassen zusätzlich Sensormodule zur Umfelderkennung, eine erweiterbare Software- und Hardwarearchitektur und Dynamikmodule für innovative Bewegungsformen.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

UNICARagil fokussiert auf die Architektur für autonomes Fahren unter dem Aspekt vielfältiger Anwendungsfälle. KI-Systeme und insbesondere wissensbasierte Methoden spielen dabei nur eine untergeordnete Rolle, d. h. im Grunde verfolgen UNICARagil und KI Wissen sehr unterschiedliche Zielsetzungen. Dennoch sind die Erkenntnisse aus UNICARagil für KI Wissen interessant.

Insbesondere könnten in KI-Wissen Bausteine der umfangreichen Simulationsumgebung genutzt werden.

8. VVMethoden

1. Beschreibung

VVMethoden verfolgt das Ziel der Entwicklung von Methoden für den Sicherheitsnachweis von vollautomatisierten und fahrerlosen Fahrzeugen zur Homologation anhand des Use Cases urbane Kreuzung. Zentrales Ergebnis ist eine Methodik zur Reduktion der Testszenarien für L4/L5-Fahrfunktionen basierend auf einem umfassenden Verständnis der Wirkzusammenhänge von Gefahren.

Zur Wiederverwendung von Testergebnissen und den Austausch von Tests zwischen Herstellern und Zulieferern wird eine Methodik zum Testen eines Gesamtsystems über die Prüfung von Subsystemen entwickelt. Basis dafür ist eine durchgängige Argumentationskette und die Verknüpfbarkeit von Nachweisen.

Darauf aufbauend wird eine L4/L5-Absicherungsinfrastruktur entwickelt, die die o.g. Methoden demonstriert und zusätzlich eine nahtlose Verbindung der Tests von Simulation bis hin zu realen Testfahrten ermöglicht. Basis hierfür ist die Entwicklung einer durchgängigen Prüfkette und Festigung von Schnittstellen der Infrastruktur.

2. Abgrenzung gegenüber und Anknüpfungspunkte zu KI Wissen

VVMethoden beschäftigt sich mit der Erarbeitung einer neuartigen Methodik für den durchgängigen Test und Validierung von Level4/5-Fahrfunktionen. Hierbei ist nicht zwingend gegeben, dass die Fahrfunktionen KI-basiert sein müssen, im Mittelpunkt steht die grundsätzliche Methodik zur Absicherung. Somit weist das Projekt VVMethoden von seinem Fokus her Anknüpfungspunkte zu den zentralen Fragestellungen des Teilprojekts 3 in KI Wissen (TP3: Wissenskonformität) auf. KI Wissen wird die Erkenntnisse aus VVM berücksichtigen und diese erweitern um die Betrachtung der Fragestellung, wie durch Nutzung unterschiedlicher Wissensquellen die Plausibilisierung und Absicherung von KI-Funktionen autonomer Fahrzeuge implementiert werden kann. KI Wissen hat in Abgrenzung zu VVMethoden einen anderen Fokus: KI Wissen konzentriert sich auf die Entwicklung von wissensbasierten Methoden sowie auf die Kombination von wissens- und datenbasierten Verfahren für den Einsatz in den KI-Funktionen autonomer Fahrzeuge. Dabei betrachtet KI Wissen nicht nur die Absicherungsthematik, sondern widmet sich genauso intensiv den Fragestellungen der Wissensintegration und Wissensextraktion.

2.5 Zusammenarbeit mit anderen Stellen

9. EICT

Das Projektvorhaben wurde von einem Projektbüro begleitet, welches die Projektpartner neben der Unterstützung als Projektbüro auch bei der Ergebnisverbreitung (Webseitenerstellung, Projektfilm, Zwischen- und Abschlusspräsentation) begleitet und zum Projekterfolg beigetragen hat.

10. Capgemini Outsourcing

Capgemini Outsourcing GmbH war Unterauftragnehmer für den GUA3 Realdatenlabeling. Als Hauptverantwortlicher für das Realdatenlabeling gab es eine enge Zusammenarbeit zwischen Valeo und Capgemini Outsourcing über das Projekt.

Capgemini Outsourcing war verantwortlich für die Anonymisierung und eine semantische Segmentierung der Daten sowie das Labeln von 3D- und 2D-Bounding-Boxen.

3 Eingehende Darstellung

Die eingehende Darstellung beginnt zunächst mit einer allgemeinen Beschreibung der jeweiligen Teilprojekte und Arbeitspakete, in denen Valeo vertreten war. Dies umfasst auch die partnerspezifische Arbeitsbeschreibung des Partners VALEO in APs aufgeteilt. Die Arbeitsfortschritte und Ergebnisse werden in zeitlicher Reihenfolge analog zu den während der Projektlaufzeit eingereichten Zwischenberichten dargestellt.

Nach der ausführlichen Darstellung der Aufgaben und Ergebnisse folgen der zahlenmäßige Nachweis, die Notwendigkeit der Förderung, die Erläuterung des Nutzen und Verwertbarkeit sowie die erfolgten Veröffentlichungen durch KI Wissen.

3.1 Erzielte Ergebnisse

3.1.1 TP1: Wissensintegration

Tabelle 3: Struktur von TP1

TP/AP	Titel	Leitung
TP1	Wissensintegration	Continental
AP1.1	A priori Wissen basierte Trainingsverfahren	fortiss
AP1.2	A priori Wissen basierte Architekturen	DFKI
AP1.3	Physikalische und mathematische Gesetzmäßigkeiten	Capgemini Engineering
AP1.4	Welt- und Expertenwissen	Bosch
AP1.5	Vernetzung von Wissensrepräsentationen	FZI

3.1.1.1 AP1.1 A priori Wissen basierte Trainingsverfahren

Aufgaben von Valeo

- Entwicklung und Umsetzung von Methoden zur Verbesserung von Lidar-basierter Fahrzeug- und Fußgängerdetektion durch geeignetes a priori Wissen (→ E1.1.1, E1.1.2, E1.1.3)
 - Einbeziehung von a priori Wissen in die Kostenfunktion.
 - A priori Wissen als zusätzlicher Input für ein neuronales Netz.
 - Verwendung von a priori Wissen zur Bezugnahme innerhalb des Netzes.
- Implementierung der Baselinemodelle, deren Leistung durch die beschriebenen Ideen verbessert werden soll.
- Auswahl von für die Aufgabe von Lidar-basierter Fahrzeug- und Fußgängerdetektion geeignetem a priori Wissen, zum Beispiel:
 - Einbeziehung von CAD-Modellen für die Fahrzeugdetektion (→ UC2, UC3)

Stand der Arbeiten (30.6.2021)

In diesem ersten Berichtszeitraum wurde zunächst eine Literaturrecherche zu den geplanten Arbeiten durchgeführt. KI-Methoden zur Erkennung von 3D-Objekten in Punktwolken werden nach der Art der Dateneingabe und nach den Phasen der Datenverarbeitung innerhalb des NNs (Abk. Für

neurales Netz) gegliedert. So existieren Architekturen mit direkter Eingabe von Punktwolken. Andere Architekturen benötigen eine zusätzliche Repräsentation der Punktwolken als Zwischenschritt. Hierbei kann die Punktwolke auf ein diskretes Gitter transformiert werden oder auch zu einem Graphen ähnlich zur konventionellen Bildbearbeitung. Bezüglich der Phasen wird zwischen einstufigen und zweistufigen Detektionsnetzwerke unterschieden. Einstufige Detektoren präzisieren in einer Phase die finalen Objekte und der Trajektorien, während zweistufige Detektionsnetzwerke die Prädiktionen in einer zusätzlichen, zweiten Phase verfeinern.

Basierend auf den Erkenntnissen aus der Literaturrecherche wurde für dieses Projekt das PointPillars Netzwerk ausgewählt [1]. Hierbei handelt es sich um einen einstufigen Detektor mit speziellem Voxelisierungsansatz. PointPillars weist im Vergleich zu anderen Architekturen kurze Inferenzzeiten auf und ist somit besser für die Anwendung im autonomen Fahren geeignet. Die schematische Netzwerkarchitektur ist im Folgenden zu sehen.




Abbildung 8: : Schematische Architektur des PointPillars-Netzwerks zur 3D-Objekterkennung auf Punktwolken [1]

Die Punktwolke wird zunächst in ein diskretes Gitter aus Säulen eingeteilt. Für jede Säule werden Merkmale extrahiert und somit eine zweidimensionale Featuremap gelernt. Diese dient im nächsten Schritt als Eingabe für eine Reihe von Convolutional-Layern, wie sie im DL (Abk. Für Deep Learning) häufig zum Einsatz kommen. Die finalen Prädiktionen werden mithilfe eines SSDs (Abk. für Single-Shot-Detection-Heads) realisiert.

Basierend auf diesem konventionellen Modell untersucht Valeo die Einbringung von Wissen. Hierbei analysieren wir die Auswirkung eines zusätzlichen Terms in der Verlustfunktion, um die zu einer Objektdetektion gehörigen Punkte mit einer Auswahl an Objektmodellen zu vergleichen.

Zusätzlich zu diesen partnerspezifischen Arbeiten hat sich Valeo aktiv an den Regeltreffen des AP1.1 beteiligt.

Stand der Arbeiten (31.12.2021)

Im Rahmen des AP1.1 arbeitet Valeo gemäß der Vorhabenbeschreibung an der Verbesserung tiefer neuronaler Netze zur 3D-Detektion von Fahrzeugen und Fußgängern mithilfe von a priori Wissen in der Kostenfunktion. Im vorliegenden Berichtszeitraum wurden diese Arbeiten ausdetailliert. In der Folge hat sich Valeo entschlossen, den Fokus zunächst auf die Erkennung von Fahrzeugen zu legen. Dort soll die Verbesserung der Ergebnisse durch a priori Wissen nachweisen werden. Durch die Covid-19 Situation entstand im Berichtszeitraum jedoch eine Überbelastung der entsprechenden Entwickelnden mit gleichzeitigem Einstellungsstopp. Dies resultierte in einem Verzug der Arbeiten

zur Erkennung von Fahrzeugen. Die entsprechenden Arbeiten sollen in den kommenden Berichtszeiträumen nachgeholt werden.

Im ersten Schritt wurde durch Valeo intensive Literaturrecherche betrieben und in der Folge ein geeignetes neuronales Netz als Baseline-Modell ausgewählt. Im Speziellen wurde das Netzwerk PointPillars¹ als Ausgangspunkt der weiteren Entwicklungen und deren Evaluierung ausgewählt. Die Leistung von PointPillars soll im weiteren Verlauf des Projekts durch den Einsatz von formalisiertem Wissen verbessert werden. Mit der Implementierung dieses Modells wurde im Berichtszeitraum begonnen.

Als Quelle für a priori Wissen im Rahmen einer 3D-Objektdetektion hat sich Valeo für die Verwendung von Objektmodellen, insbesondere Personenkraftwagen, entschieden. Diese Objektmodelle sollen mithilfe geeigneter Maße mit den Detektionen des neuronalen Netzes verglichen und quantifiziert werden, sodass die Kombination von Modell und Prädiktion im Rahmen der Kostenfunktion beim Training des Netzes berücksichtigt werden kann.

Für die Repräsentation dieser Modelle gibt es verschiedene Möglichkeiten. Auf Basis aktueller Literatur ist es nicht möglich, sich eindeutig für eine einzige Repräsentation zu entscheiden. Daher sollen verschiedene Repräsentationen verwendet und miteinander verglichen werden. Im ersten Schritt werden hierfür Gaußsche Mischverteilungen betrachtet und getestet. Im Anschluss muss abhängig von der gewählten Repräsentation eine entsprechende Metrik bestimmen werden. Zu diesem Zeitpunkt kann noch keine Aussage über die beste Wahl getroffen werden. Im Falle der Gaußschen Mischverteilungen wäre eine Betrachtung der Wahrscheinlichkeitsdichten einzelner Objektprädiktionen eventuell ein geeigneter Ansatz. Im weiteren Verlauf der Arbeiten sollen entsprechende Mischverteilungen aus den Testdaten bestimmt werden. Ob hierbei ein Modell für alle Objekte der Kategorie Personenkraftwagen oder verschiedene Modelle abhängig von dem relativen Winkel und der Distanz zu besseren Ergebnissen führen, ist dabei zu klären.

Stand der Arbeiten (30.6.2022)

In diesem Berichtszeitraum arbeitete Valeo im Rahmen des AP1.1 weiter an der Verbesserung tiefer neuronaler Netze zur 3D-Detektion von Fahrzeugen- und Fußgängern mithilfe von a priori Wissen in der Kostenfunktion. Wie bereits im letzten Bericht erläutert, liegt der Fokus auf einem numerischen Vergleich zwischen den vom Netz prädizierten Personenkraftwagen und dem entsprechenden CAD-Modell. Letzteres bildet das apriori Wissen.

Das PointPillars Netzwerk¹, welches als Ausgangspunkt für die weiteren Arbeiten dient, wurde in diesem Berichtszeitraum fertiggestellt und evaluiert. Die Ergebnisse der originalen Arbeit konnten reproduziert werden. Des Weiteren wurde eine modulare Möglichkeit für die Einbeziehung der Vergleichswerte von Modell und Prädiktionen implementiert. Das umfasst die Extraktion der Punkte pro prädizierter Box sowie das modulare Einbeziehen der Vergleichswerte in die Kostenfunktion des Netzes. Hierbei wurden mehrere Sonderfälle festgestellt, die im weiteren Verlauf der Arbeiten genauer betrachtet werden müssen. Die Sonderfälle umfassen das Fehlen von

¹ A. H. Lang, S. Vora, H. Caesar, L. Zhou, J. Yang, and O. Beijbom. „Pointpillars: Fast encoders for object detection from point clouds.“ In: CVPR, 2019.

Prädiktionen, sowie dem Fall, dass keine Punkte in den prädizierten Boxen vorhanden sind. In all diesen Fällen ist ein Vergleich der Prädiktion mit dem Modell nicht sinnvoll.

Die Repräsentation des Personenkraftwagens ist weiterhin der Schwerpunkt der aktuellen Arbeit (siehe AP1.4). In diesem Berichtszeitraum wurden die im letzten Bericht bereits erwähnten Gaussian Mixture Models erzeugt, implementiert und auf ihre Nutzbarkeit für unseren Anwendungsfall hin untersucht. Als Vergleichsmetrik wurde zunächst die Likelihood der Wahrscheinlichkeitsdichtefunktion verwendet. Tatsächlich konnte festgestellt werden, dass die Likelihood für besser prädizierte Boxen einen nützlichen Vergleichswert liefert. Die Ausgabe der Likelihood-Funktion ist allerdings nicht zwangsläufig größer 0, was eine direkte Verwendung in der Kostenfunktion verhindert. Andere Optionen wie die Verwendung eines Mahalanobis-Abstands wurden aufgrund ihrer Komplexität im Falle dreidimensionaler Gaussian Mixture Models nicht weiterverfolgt.




Abbildung 9: : Horizontal ist die Nummer aller von PointPilers prädizierten Boxen vom Kitti validation split aufgetragen. Vertikal sind die Werte der genormten Chamfer-Distanz und der IoU (Abkürzung für "Intersection over Union") aufgetragen.

Die Repräsentation des Automodells mithilfe einer dichten Punktwolke wurde ebenso umgesetzt. Als Vergleichsmetrik dient hier die Chamfer-Distanz. Auch hier wurde zunächst untersucht, ob sich eine Korrelation mit der Güte der geschätzten Box feststellen lässt. In Abbildung 9 sind alle prädizierten Boxen sortiert nach der Chamfer-Distanz zwischen Objektmodell und Punkten in der jeweiligen prädizierten Box geordnet abgebildet (rot). In grün sind ist die IoU (Abkürzung für "Intersection over Union", d.h. die Schnittmenge geteilt durch die Gesamtmenge) der prädizieren Boxen mit den Referenzdaten aufgetragen. Die beiden Datensätze scheinen unkorreliert. Basierend auf der Chamfer-Distanz können wir daher keine Aussage über die Güte der Prädiktion treffen. Grund hierfür könnte die ungleiche Anzahl an Punkten von Modell und Prädiktionen sein.

Für die weiteren Arbeiten sind Untersuchungen bezüglich weiterer Wissensrepräsentationen, Anpassungen der Repräsentation mittels dichter Punktwolke, sowie eine Behandlung der genannten Sonderfälle geplant.

Darüber hat sich Valeo bei den regelmäßigen Telefonkonferenzen eingebracht und sowohl für den Open Project Day als auch den TP1 Workshop aktive Beiträge in Form von Vorträgen und Postern geliefert.

Stand der Arbeiten (31.12.2022)

In diesem Berichtszeitraum arbeitete Valeo im Rahmen des AP1.1 weiter an der Verbesserung tiefer neuronaler Netze zur 3D-Detektion von Fahrzeugen und Fußgängern mithilfe von *a priori* Wissen in der Kostenfunktion.

Um die Ergebnisse des AP1.1 zu erfüllen, hatte Valeo den Ansatz gewählt, CAD Modelle mit den prädizierten Objektpunkten eines 3D-Objektdetektors zu vergleichen. Hierfür musste eine geeignete Repräsentation sowie eine Vergleichsmetrik gefunden werden. Wie im letzten Berichtszeitraum dargelegt, wurden verschiedene Repräsentationen und Metriken in Erwägung gezogen und entsprechend ihrer Eignung für den gewählten Ansatz untersucht. Diese Untersuchungen wurden in diesem Berichtszeitraum fortgesetzt. Dabei konnte jedoch keine Repräsentation der Objektmodelle mit den gewünschten Eigenschaften gefunden werden. Aus diesem Grund hat Valeo die Entscheidung getroffen, den Ansatz entsprechend anzupassen. Nach einer erneuten Sichtung des aktuellen Standes der Technik wurde ein neuer Ansatz für die Vorhaben in AP1.1 mit dem Namen AGO-Net² gefunden. Das grundsätzliche von Valeo vorgestellte Konzept, Objektmodelle als *a-priori* Wissen zu verwenden, um mittels einer zusätzlichen Kostenfunktion die Qualität eines 3D-Objektdetektors zu verbessern, bleibt hierbei bestehen.

Die Objektmodelle sollen nun jedoch nicht mehr direkt mit den Prädiktionen verglichen und als Kostenfunktion verwendet werden. Stattdessen wird der Vergleich auf Merkmalsebene im Netz durchgeführt. Dazu wird zusätzlich zu dem originalen Trainingsdatensatz ein sogenannter konzeptioneller Datensatz aufgebaut. Hierfür werden alle Objekte in den originalen Daten mit Objektmodellen ausgetauscht. Auf diesem konzeptionellen Datensatz wird ein beliebiger 3D-Objektdetektor mit den herkömmlichen Verfahren trainiert. Dieser konzeptionelle Detektor wird nun in einem Teacher-Student Ansatz verwendet, um einen perzeptuellen 3D-Objektdetektor, dessen Architektur dem des konzeptionellen Detektors gleicht, zu trainieren. Das Verfahren ist in Abbildung 10, entnommen aus der Veröffentlichung des AGO-Net, schematisch dargestellt.




Abbildung 10: Schematische Darstellung des AGO-Net Ansatzes, um Objektmodelle als *a-priori* Wissen zu verwenden. Ein konzeptueller Objektdetektor wird verwendet, um das Wissen während des Trainings auf die perzeptuellen Beispiele zu übertragen [aus AGO-Net Publikation]

Der perzeptuelle Detektor wird hierzu mit den originalen Daten trainiert. Zusätzlich werden die entsprechenden originalen Daten in ihrer konzeptuellen Variante entsprechend mittels des

² Du, Liang, et al. "Ago-net: Association-guided 3d point cloud object detection network." *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2021).

konzeptionellen Detektors prozessiert. Die Gewichte des konzeptionellen Detektors sind dabei eingefroren. Die Merkmalskarten der letzten Layer der beiden Detektoren werden nun während des Trainings entsprechend der Position der Groundtruthobjekte maskiert und anschließend die Abweichung der beiden als zusätzliche Kostenfunktion verwendet. Dadurch soll das konzeptionelle Wissen über die Objektmodelle durch den konzeptionellen Detektor an den perzeptuellen Detektor weitergegeben werden. Für die Inferenz wird nur der perzeptuelle Objektdetektor verwendet.

Die Autoren des AGO-Net verwenden in den gezeigten Experimenten keine Objektmodelle, sondern reichern für den konzeptuellen Datensatz die originalen Objekte mit Punkten an, die aus dem Trainingsdatensatz selbst extrahiert wurden. Dieses Vorgehen wird von Valeo zunächst adaptiert, um eine Vergleichbarkeit mit den Ergebnissen der Originalarbeit herzustellen. Valeo hat bereits damit begonnen, die konzeptionelle Datenbasis derart aufzubauen. Zu einem späteren Zeitpunkt plant Valeo Experimente mit den in den bisherigen Arbeiten bereits aufgearbeiteten CAD-Modellen durchzuführen. Weiterhin soll das bereits implementierte und in das im Projekt verwendete Gitlab eingepflegte PointPillars Netzwerk³ auch weiterhin als Baseline-Modell dienen und als Architektur für perzeptuellen und konzeptionellen Detektor verwendet werden.

Darüber hinaus hat sich Valeo bei den regelmäßigen Telefonkonferenzen eingebracht.

Stand der Arbeiten (30.6.2023)

In diesem Berichtszeitraum arbeitete Valeo im Rahmen des AP1.1 zunächst weiter an der Verbesserung tiefer neuronaler Netze zur 3D-Detektion von Fahrzeugen und Fußgängern mithilfe von *a priori* Wissen in der Kostenfunktion.

Die im letzten Berichtszeitraum begonnene Arbeit bezüglich der Verwendung des AGO-Net, das CAD Objektmodelle zum Verbessern des Trainings verwendet, wurde zunächst fortgesetzt. Bei der Implementierung traten jedoch Probleme auf, die ein Weiterarbeiten zunächst nicht möglich machten. Aus diesem Grund wurde die Arbeit an diesem Thema zunächst pausiert und wird, falls es die geplanten PM in diesem Arbeitspaket zulassen, später fortgesetzt.

Stattdessen wurde eine neue Idee entwickelt, die jedoch nicht mehr das a-priori Wissen in die Kostenfunktion integriert, sondern bei der Augmentierung der Daten zum Tragen kommt. Hierbei wurde der Fokus auf den Use Case 1.6 gelegt, bei dem eine Infrastruktur Sensorik angenommen wird, um Verkehrsteilnehmer auf einem Parkplatz bestmöglich zu detektieren. Dabei soll die statische Umgebung in diesem Use Case ausgenutzt werden.

Die Ground Truth Sampling Augmentierungsmethode ist eine der meistgenutzten Augmentierungsmethoden für 3D Objekterkennung mit LiDAR Daten. Hierbei wird eine Datenbasis von Objekten erstellt, indem diese aus dem Trainingsdatensatz ausgeschnitten werden. Zur Trainingszeit werden dann zufällige Objekte aus der Datenbasis ausgewählt und in den aktuellen Frame eingefügt. Dadurch wird künstlich die Variabilität der Daten erhöht und somit ein besseres Training ermöglicht. Die Objekte werden jedoch nur an der Stelle eingefügt, in der sie initial ausgeschnitten wurden. Valeo hat in diesem Berichtszeitraum zunächst andere Varianten zum

³ Lang, Alex H., et al. "Pointpillars: Fast encoders for object detection from point clouds." *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2019.

Einfügen der Objekte untersucht, um die statische Umgebung besser auszunutzen. Die verschiedenen Varianten sind in Abbildung 11 schematisch dargestellt.




Abbildung 11: Eine Skizze für alle acht Ground Truth Sampling Variationen ist dargestellt. Der LiDAR-Sensor ist als schwarzes Quadrat dargestellt. Kästchen und Punkte beziehen sich auf ein exemplarisches Objekt, das alle acht Varianten umfasst. Die Linien innerhalb der Kästchen zeigen die Ausrichtung an. Die Farben der Kästchen stehen für die Positionsvariante, die Farben der mittleren Linien die Orientierungsvariante. Der gestrichelte Kreis zeigt den polaren Abstand der Ground Truth Position.

Beim Einfügen der Objekte aus der Datenbasis ist es möglich, dass Objekte nicht an sinnvolle Positionen gesetzt werden. Hier kann das a-priori Wissen, um die statische Umgebung verwendet werden. Zunächst wurde ein einfaches Polygon gezeichnet, um die Fläche zu markieren, in der Objekte eingefügt werden dürfen. Objekte wurden nur innerhalb des Polygons eingefügt, nicht außerhalb.

Mit diesen verschiedenen Varianten und der Verwendung des Polygons wurden erste Experimente gemacht, die im folgenden Berichtszeitraum weiter fortgesetzt werden sollen.

Des Weiteren wurde damit begonnen, das Netzwerk in den Demonstrator zu integrieren.

Darüber hinaus hat sich Valeo bei den regelmäßigen Telefonkonferenzen eingebracht.

Stand der Arbeiten (31.12.2023)

In diesem Berichtszeitraum arbeitete Valeo im Rahmen des AP1.1 weiter an der Verbesserung tiefer neuronaler Netze zur 3D-Detektion von Fahrzeugen und Fußgängern mithilfe von *a priori* Wissen. Dieses soll über die Augmentierungsmethoden in den Trainingsprozess eingebunden werden.

Wie im letzten Berichtszeitraum bereits erläutert, wird die Ground Truth Sampling Augmentierungsmethode hierfür verwendet. Bei dieser Augmentierungsmethode wird eine Datenbasis von Objekten erstellt, indem diese aus dem Trainingsdatensatz ausgeschnitten werden. Zur Trainingszeit werden dann zufällige Objekte aus der Datenbasis ausgewählt und in den aktuellen Frame eingefügt. Dadurch wird künstlich die Variabilität der Daten erhöht und somit ein besseres Training ermöglicht.

Valeo hat verschiedene Varianten zum Einfügen der Objekte getestet. Die verschiedenen Varianten sind in Abbildung 12 nochmals schematisch dargestellt.




Abbildung 12: Eine Skizze für alle acht Ground Truth Sampling Variationen ist dargestellt. Der LiDAR-Sensor ist als schwarzes Quadrat dargestellt. Die Boxen und Punkte beziehen sich auf ein exemplarisches Objekt, das alle acht Varianten umfasst. Die Linien innerhalb der Boxen zeigen die Ausrichtung an. Die Farben der Boxen stehen für die Variante der Positionierung, die Farben der mittleren Linien die Variante der Orientierung. Der gestrichelte Kreis zeigt den polaren Abstand der Ground Truth Position.

Das Einfügen der Objekte kann in die Wahl der Position und die Wahl der Orientierung der Objekte geteilt werden. Die meistgenutzte Variante für beides ist “Ground Truth”. Hierbei werden Position und Orientierung von dem original Objekt übernommen. Bei der Wahl der Positionierung und der Orientierung “Random” werden die Positionskoordinaten und der Orientierungswinkel gleichverteilt zufällig gezogen. Bei der “Polar” Positionierung wird das Objekt so platziert, dass die ursprüngliche Distanz zum Sensor beibehalten wird. Die “relative” Orientierung beschreibt die gleiche Idee, nur für den Orientierungswinkel. Basierend auf der neuen Position eines Objektes wird hier der Winkel so gewählt, dass er relativ zum Sensor gleich bleibt.

Die Experimente wurden auf einem Valeo internen Datensatz durchgeführt. Hierfür wurden mehrere LiDAR Sensoren verwendet, um eine Parkplatzsituation ähnlich zu Use Case 1.6 aufzunehmen. Die LiDAR Sensoren sind dabei fest in der Umgebung installiert. Zwei verschiedene Netzwerke PointPillars und CenterPoint wurden für die Experimente verwendet. Jedes Training wurde sechs mal durchgeführt und der Median angegeben. Die Ergebnisse für PointPillars sind in Tabelle 4 zu sehen. Die Ergebnisse für CenterPoint sind in

Tabelle 5 dargestellt.

Tabelle 4: Die mean average precision von Auto und Fußgänger für PointPillars mit verschiedenen Kombinationen von GT-Sampling-Methoden. Die linken Werte für jede Zelle sind ohne Polygon. Die Werte neben den Netznamen sind die Baseline Ergebnisse ohne GT-Sampling. Die ausgewiesenen Werte sind der Median von jeweils sechs Trainings. Höhere Werte sind besser. Die besten Ergebnisse sind fett markiert.

Mean Average Precision in % ↑ PointPillars (62.82)			
Position / Orientation	Ground Truth	Random	Relative
Ground Truth	63.31 / 63.54	63.92 / 64.26	-
Random	63.92 / 66.61	63.22 / 65.49	64.35 / 65.70
Polar	64.16 / 65.16	63.84 / 64.81	63.63 / 65.72

Tabelle 5: Die mean average precision von Auto und Fußgänger für CenterPoint mit verschiedenen Kombinationen von GT-Sampling-Methoden. Die linken Werte für jede Zelle sind ohne Polygon. Die Werte neben den Netznamen sind die Baseline Ergebnisse ohne GT-Sampling. Die ausgewiesenen Werte sind der Median von jeweils sechs Trainings. Höhere Werte sind besser. Die besten Ergebnisse sind fett markiert.

Mean Average Precision in % ↑ CenterPoint (68.58)			
Position / Orientation	Ground Truth	Random	Relative
Ground Truth	71.78 / 70.71	72.04 / 72.01	-
Random	72.14 / 72.95	72.51 / 72.96	72.46 / 72.64
Polar	72.32 / 73.50	72.27 / 72.02	72.16 / 71.58

Obwohl die Kombination aus Polar Positionierung und Relativer Orientierung im ersten Moment aus menschlicher Perspektive am realistischsten erscheint, ist sie nicht die beste Variante. Das kann mit dem Multisensor Setup erklärt werden, indem es, bedingt durch die verschiedenen Blickwinkel der Sensoren, keinen klaren Bezugspunkt gibt. Des Weiteren kann beobachtet werden, dass die gängige Ground Truth Einfügung nicht die beste ist. Es ist erkennbar, dass die Art und Weise des Einfügens der Objekte einen Einfluss auf die Güte des Netzes hat.

Das Einfügen der Objekte aus der Datenbasis kann auch an nicht sinnvollen Positionen erfolgen. So zum Beispiel können die Objekte auch in Wänden oder außerhalb befahrbarer/begehrbarer Flächen eingefügt werden. Um Fehler solcher Art bei der Augmentierung zu umgehen, kann das a-priori Wissen, um die statische Umgebung verwendet werden. Es wurde ein einfaches Polygon gezeichnet, um die Fläche zu markieren, in der Objekte eingefügt werden dürfen. Objekte wurden nur innerhalb des Polygons eingefügt, nicht außerhalb. Die Experimente wurden auf die gleiche Weise unter Verwendung des Polygons wiederholt. Die Ergebnisse sind wieder in den beiden Tabellen abzulesen. Unter Verwendung des Polygons verbessert sich die Güte der Netzwerke weiter.

Anschließend wurden Experimente durchgeführt, um zu untersuchen, inwieweit die Verwendung der Polygone als a-priori Wissen eine geringe Menge gelabelter Daten ausgleichen kann. Hierzu wurde der Trainingsdatensatz verkleinert auf 75%, 50% und 25% der ursprünglichen Menge. Die Experimente wurden auf den verschiedenen Trainingssätzen auf die gleiche Weise wiederholt. Die Ergebnisse sind in Abbildung 13 und Abbildung 14 zu sehen




Abbildung 13: Die mean average precision (Auto und Fußgänger) auf den verschiedenen Größen der Trainingsplits für PointPillars ohne (rot) und mit (blau) GT-Sampling. Die Unterschiede in den Medianen zwischen ohne und mit GT-Sampling für jede Datensatzgröße werden in der unteren linken Ecke angezeigt. Am besten zu sehen bei Vergrößerung und in Farbe.




Abbildung 14: Die mean average precision (Auto und Fußgänger) auf den verschiedenen Größen der Trainingsplits für CenterPoint ohne (rot) und mit (blau) GT-Sampling. Die Unterschiede in den Medianen zwischen ohne und mit GT-Sampling für jede Datensatzgröße werden in der unteren linken Ecke angezeigt. Am besten zu sehen bei Vergrößerung und in Farbe.

Für beide Netze lässt sich erkennen, dass die Verwendung der Augmentierung die schlechtere Güte der Netze durch die geringere Datenmenge etwas abfedern kann. So steigt der Nutzen der Gt Sampling Methode, je weniger Daten im Training zur Verfügung stehen.

Zum besseren Verständnis der vorgestellten Methode, sowie zur Vergleichbarkeit der Ansätze zur Integration von a-priori Wissen wurde außerdem ein Design Pattern nach Bekkum et al.⁴ erstellt. Es ist in Abbildung 15 dargestellt. Die in grün markierten semantischen Informationen sind hierbei die Polygone zum Begrenzen der zum Einfügen von Objekten geeigneten Fläche zur Datenaugmentierung.

⁴ van Bekkum et al.: "Modular design patterns for hybrid and reasoning systems: a taxonomy, patterns and use cases", Appl. Intell. 51, 6528 (2021)




Abbildung 15: Design Pattern der dargestellten Methode nach Bekkum et al.. Das a-priori Wissen ist in grün markiert

Darüber hinaus hat sich Valeo bei den regelmäßigen Telefonkonferenzen eingebracht.

Stand der Arbeiten (31.3.2023)

In diesem Berichtszeitraum hat Valeo untersucht, inwieweit die Nutzung der Semantik als a-priori Wissen für die Augmentierung auch in dynamischen Szenarien genutzt werden kann. Hierzu wurden auf dem öffentlich verfügbaren Nuscenes Datensatz Experimente durchgeführt. Anstelle des Gültigkeitspolygons wurden hier die verfügbaren semantischen Annotierungen genutzt, um die Fläche zum Einfügen der Objekte einzugrenzen. In diesem Fall konnten jedoch im Rahmen des geringen Zeitrahmens keine Verbesserungen festgestellt werden.

3.1.1.2 AP1.2 A priori Wissen basierte Architekturen

1. Aufgaben von Valeo

- Entwicklung einer wissensbasierten Objekterkennung in der Anwendung Automated Valet Parking basierend auf statischen und dynamischen Kamerabildern (↔ Altran).
 - Einbeziehung von wissensbasierten Modellen in die Kostenfunktion.
 - Verwendung von wissensbasierten Modellen als zusätzlichen Input.
 - Verwendung von wissensbasierten Modelle zur Bezugnahme innerhalb der Netze.

Stand der Arbeiten (30.6.2021)

Der Schwerpunkt von Valeo in diesem Arbeitspaket ist die Entwicklung einer wissensbasierten Methode zur Eigendiagnose von Lidar-Sensoren. Ein Lidar-Sensor misst die Entfernung von Objekten über Laufzeitmessungen von reflektierten Laserstrahlen. Durch eine horizontale Rotation eines Umlenkspiegels und eine vertikale Anordnung mehrerer Laser- und Photodioden wird ein definierter Raumwinkel abgetastet. Die Position und Intensität der gemessenen

Punktwolke hängt damit empfindlich an der Sende- und Empfangsoptik. Eine Verschiebung der Optik im jahrelangen Betrieb der Sensoren am Fahrzeug kann jedoch nicht ausgeschlossen werden.

Valeo ist an einer Erkennung von intrinsischen Störungen in der Detektion interessiert, welche die Zuverlässigkeit der Sensoren einschränken. Diese Störungen können sich unter Umständen kritisch auf die Fußgängererkennung und auf Spurwechselmanöver (Uses Cases 1 und 2 von KI Wissen) auswirken.

Zu Beginn des Berichtszeitraums wurden Störungen durch Alterung der Sensoren als besonders relevant für die automatisierte Fahrfunktion identifiziert. Das Erkennen von Alterungseffekten im normalen Fahrbetrieb durch konventionelle Algorithmen stellt eine Herausforderung dar. Die Einführung von wissensbasierter KI zur Detektion von Alterungseffekten ist mit vorhandenem Wissen bei Valeo zur Lidar-Technologie und den großen Datenmengen aus dem realen Fahrbetrieb ein vielversprechender Ansatz.




Abbildung 16: Punktwolken eines Lidar-Sensors (Scala Generation 2 von Valeo) in Vogelperspektive vor (linkes Bild) und nach (rechtes Bild) Verstellen der Optik. Die Punkte sind je nach Empfangsdiode farblich markiert

Für eine erste Datenerhebung wurden insgesamt diversen Testfahrten mit unterschiedlichen Degradationsgraden der Optik durchgeführt. Die Daten wurden auf einer Referenzstrecke (Autobahn) unter optimalen Bedingungen (gutes Wetter, trockene Straße, saubere Sensorfront, kein direktes Sonnenlicht) eingefahren. Die Punktwolken in Abbildung 16 wurden vor (linkes Bild) und nach (rechtes Bild) Verstellen der Optik aufgenommen. Die unterschiedlichen Umgebungen der gezeigten Bilder erschweren eine Analyse. Der Einsatz von wissensbasierter KI über einen längeren Zeitraum kann hier nach unseren Erwartungen einen Mehrwert liefern.

Es wurde eine Analyse durchgeführt, welches vorhandene Wissen in einem neuronalen Netz zur Alterungserkennung eingebracht werden kann. Als erstes wurde Wissen über den mechanischen Aufbau des Sensors herangezogen. Eine dejustierte Optik kann zu periodischen, blinden Flecken im Sichtbereich führen. Durch diese Merkmale können Alterungseffekte eventuell von anderen Effekten, wie Rauschen, unterschieden werden.

Laut aktuellem Stand der Technik existieren verschiedene neuronale Netze zur Analyse von unsortierten 3D-Punktwolken, wobei ein explizites Nutzen hier vorwiegend noch nicht thematisiert wird. Arbeiten hierzu sind bei Valeo im weiteren Verlauf des Projektes geplant. Ein mögliches Ausgangsmodell ohne explizites Wissen beginnt mit Umwandlung der Punktwolke in ein Voxelgitter, dessen geordnete Struktur die Anwendung von Faltungsoperationen im neuronalen Netz ermöglicht. Diese Ansätze sind in der Bildanalyse weit verbreitet. Im Falle von Punktwolken wird jedoch die Datenmenge einer ursprünglich dünn besetzten Punktwolke sehr stark erhöht. Ein weiterer Ansatz ist die Projektion der Punktwolke in verschiedene zweidimensionale Ebenen, die dann mit Faltungsnetzen (convolutional neural networks) weiterverarbeitet werden.




Abbildung 17: 3D-Darstellung einer Punktwolke als Eingabe für das PointNet

Nach Studium des aktuellen Stands der Technik planen wir eine Nutzung des sogenannten PointNet [2]. Die Besonderheit dieses Netzes besteht in der direkten Analyse der 3D-Punktwolke (siehe Abbildung 17), wodurch Informationsverlust durch die Projektionen vermieden wird. Mit diesem neuronalen Netz soll eine Klassifikation in verschiedene Alterungsklassen durchgeführt werden. Aktuell laufen bereits vorbereitende Maßnahmen zur Anwendung des PointNets auf den real gemessenen Punktwolken.

Die Zuverlässigkeit bei der Bestimmung von Alterungseffekten ist ausschlaggebend für einen späteren kommerziellen Einsatz. Falsch positive Detektionen führen zu hohen Kosten und Unzufriedenheit der Kunden. Falsch negative Detektionen gefährden die Sicherheit im Betrieb.

Gleichzeitig ist aber die Gewinnung von hochwertigen Trainingsdaten von gealterten Sensoren für eine hohe Zuverlässigkeit der Alterungsbestimmung eine Herausforderung, da sich der Alterungsprozess über viele Jahre erstreckt. Des Weiteren benötigen neuronale Netze generell eine enorme Menge an Messdaten mit einer repräsentativen Anzahl an Sensoren. Arbeiten zur gezielten Aufnahme von Daten sind daher bei Valeo geplant.

Stand der Arbeiten (31.12.2021)

Im AP1.2 untersucht Valeo interne Dejustierungen von LiDAR-Sensoren am Falle des Scala® Generation 2 von Valeo. Falls solche Dejustierungen im laufenden Fahrbetrieb auftreten, wirken sie sich entscheidend auf die Perzeption und damit den Fahrbetrieb aus. Die Beurteilung des Zustands und der Datenqualität von LiDAR-Sensoren ist daher für das autonome Fahren von großer Bedeutung. Eine Untersuchung der Zeitskalen, in denen diese Alterungseffekte auftreten, sind Teil der geplanten Arbeiten.

Für die Erkennung der Dejustierung wird in den aktuellen Arbeiten das neuronale Netzwerk Rangenet++⁵ zugrunde gelegt. Dieses Netz ist für semantische Segmentierung von Punktwolken ausgelegt und wurde auf die Klassifizierungsaufgabe angepasst. Es projiziert die ursprüngliche Punktwolke aus drei Dimensionen auf eine zweidimensionale, sphärische Oberfläche, sodass ein sogenanntes Tiefenbild entsteht⁶. Diese Projektion ermöglicht die Anwendung von bewährten Faltungsoperatoren aus der Bilderkennung.

Eine Wissensquelle für mögliche Verbesserungen von künstlicher Intelligenz ist die Hardware des LiDAR-Sensors. Der rotierende Spiegel mit vertikaler Rotationsachse und die vertikal angeordneten Laserdioden resultieren in vertikal aufgeschichtete Detektionsebenen. Der Valeo Scala 1 Sensor hat beispielsweise 4 Lagen, der Scala 2 Sensor 16. Die Firmen Velodyne und Ouster stellen LiDAR-Sensoren mit 16, 32, 64 und 128 Lagen her. Mit diesem Wissen können die Punkte in der Punktwolke angeordnet werden. Rangenet++ projiziert die ursprüngliche Punktwolke auf eine sphärische Oberfläche basierend auf der bekannten Geometrie der Detektionsebenen. Die kartesischen Koordinaten (x,y,z), der Abstand und die Echopulsweite werden in den Kanälen des Tiefenbilds gespeichert, wodurch sich ein Feld der Größe $[N \times M \times 5]$ ergibt, wobei N die Anzahl der Lagen ist und M die Anzahl der Punkte pro Detektionsebene. Mit diesem Ansatz vermeidet man Diskretisierungsfehler.

Zuerst werden alle Punkte mit demselben horizontalen Winkel gespeichert. Danach wird der horizontale Winkel variiert. Dieses Wissen wird normalerweise für ungeordnete Punktwolken nicht verwendet. Vor diesem Hintergrund könnte es interessant sein, Faltungsfilter mit größerer Ausdehnung in vertikaler als in horizontaler Richtung zu verwenden. Damit können Verzerrungseffekte während der Datenaufnahme der LiDAR-Sensoren abgeschwächt werden, welche durch die Bewegung des Egofahrzeugs bei gleichzeitiger Rotation des Abtastspiegels verursacht werden. Im Falle des Scala 2 sind Experimente mit Filtergrößen von $[16 \times 1]$, $[16 \times 3]$ und $[8 \times 1]$, $[8 \times 3]$ geplant. Im Falle von LiDAR-Sensoren mit einer weitaus höheren Anzahl an

⁵ A. Milioto and I. Vizzo and J. Behley and C. Stachniss: RangeNet++: Fast and accurate LiDAR semantic segmentation, IEEE/RSJ Intl.-Conf.-on Intelligent Robots and Systems (IROS), 2019

⁶ Yulan Guo, Hanyun Wang, Qingyong Hu, Hao Liu, Li Liu, and Mohammed Bannamoun: "Deep learning for 3d point clouds: A survey", <https://arxiv.org/abs/1912.12033>, 2020

Detektionsebenen, wie z. B. 128, ist eine Ausdehnung des Filters über alle Detektionsebenen nicht sinnvoll. Filter mit geradzahlgiger Kantenlänge werden in CNNs bisher wenig genutzt. Jedoch konnte gezeigt werden, dass solche Filter in Kombination mit dem sogenannten Padding, d. h. dem geeigneten Auffüllen der Ränder, klassischen $[3 \times 3]$ -Filtern überlegen sind⁷.

Ein weiterer Wissensbaustein ist die Anzahl der Laserdioden des Senders und die Anzahl der Lawinendioden des Empfängers. In diesem Zusammenhang untersucht Valeo den Stride, d. h. die Schrittweite der Filter. Die Berechnungsgeschwindigkeit könnte durch eine Variation des Strides verbessert werden. Dies hat enorme Bedeutung für die Echtzeitfähigkeit der finalen Erkennungsfunktion für Desjustierungen im automatisierten Fahrzeug.

Rangenet++ verwendet sogenannte "gedehnte" Filter, bei denen die berücksichtigten Bildpixel nicht direkt nebeneinanderliegen. Dadurch kann verteilte Kontextinformation einbezogen werden, ohne die Anzahl der Filterparameter zu erhöhen. Valeo untersucht in der Folge, ob eine Anpassung des Dehnungsfaktors auf die Anzahl der Dioden sinnvoll ist.




Abbildung 18: Schematische Darstellung des Sichtfeldes eines LiDAR-Sensors bestehend aus Sende- und Empfangsbereich. Links ist der Normalfall gezeigt. In der rechten Zeichnung sind Sender und Empfänger relativ zueinander verstellt.

Eine weitere Idee zur Integration von Wissen bezieht sich auf die Ausrichtung von Sender und Empfänger. Deren Ausrichtung strebt eine optimale Überlappung der beiden Sichtbereiche in den relevanten Detektionsabständen an. Dies ist links auf Abbildung 18 dargestellt. Aufgrund von Alterungseffekten kann es zu einer relativen Verstellung von Sender und Empfänger kommen. Dadurch wird deren Überlappungsbereich kleiner, was rechts auf Abbildung 19 gezeigt ist. Dies wirkt sich auf die Erkennung von Objekten aus, insbesondere von schmalen Objekten in großer Entfernung (siehe links auf Abbildung 19). Beispielsweise könnten Leitpfosten in großer Entfernung nicht mehr erkannt werden, falls sie zwischen die Bereiche maximaler Überlappung fallen. In einem bewegten Egofahrzeug kann ein weiterer Effekt erwartet werden. Beim Durchlaufen eines weit entfernten Pfostens durch das Sichtfeld verschwindet dieser zeitweise und taucht wieder auf, je nachdem ob seine Position gerade auf einen Überlappungsbereich von Sender und Empfänger fällt oder dazwischen. Im kommenden Berichtszeitraum soll dieser Effekt experimentell nachgewiesen werden.

⁷ Shuang Wu, Guanrui Wang, Pei Tang, Feng Chen, and Luping Shi: "Convolution with even-sized kernels and symmetric padding", <https://arxiv.org/abs/1903.08385>, 2019




Abbildung 19: Das Sichtfeld eines idealen LiDAR-Sensors ist links gezeigt. Das rechte Bild entspricht einem LiDAR-Sensor mit verstellter Optik.

Das genannte Wissen über das Modell der LiDAR-Sensoren kann in einer Datei zur Verfügung gestellt werden, die vom Netz eingelesen wird. Dafür würde sich beispielsweise YAML (Abk. für "Yet Another Markup Language") anbieten. YAML ist ein weit verbreitetes Format zur Serialisierung von Daten.

Stand der Arbeiten (30.6.2022)

Im Rahmen der Kundenfunktionen "Automated Valet Parking" (AVP) und "Autonomes Fahren im Werk" (AFW) arbeitet Valeo in AP1.2 seit Beginn des vorliegenden Berichtszeitraumes an wissensbasierter Objekterkennung mittels statischen Kameras. Typischerweise werden die Kameras an Wänden oder Decken montiert. Es werden keine Sensoren des Autos benutzt. Die Auswertung der Perzeptionsdaten und die Steuerung des Fahrzeugs erfolgen ebenfalls über die Infrastruktur des Parkhauses bzw. der Produktionsstätte.

Eine Herausforderung für die Objekterkennung sind die falsch-positiven Detektionen von Personen und anderen Objekten. Beispielsweise zeigt Abbildung 20 wie der Eingang zur einer Waschstraße fälschlicherweise als Person klassifiziert wird. Fälschlichen Detektionen dieser Art wollen wir mit dem Einsatz von Wissen entgegenwirken. Dieses Wissen bildet ein statisches Kamerabild der reinen Infrastruktur, d.h. ein Bild ohne dynamische Objekte wie Fahrzeuge oder Personen. Abbildung 21 zeigt eine Beispiel einer Kamera in einem Parkhaus mit und ohne dynamische Objekte.




Abbildung 20: Der Eingang einer Waschstraße wird fälschlicherweise als Person mit einer Konfidenz von 0.38 erkannt.

Ein aktuell von uns genutztes neuronales Netz ist YOLACT⁸ (Abkürzung für "You Only Look At Coefficients"). Dabei handelt es sich um ein einstufiges, echtzeitfähiges Netz zur Objektdetektion und zur Instanzsegmentierung. Dieses Netz wird als Ausgangspunkt für die Integration des Wissens aus dem statischen Bild in die Architektur benutzt.




Abbildung 21: Aufnahmen einer Kamera in einem Parkhaus mit dynamischen Objekten auf dem linken Bild und ohne auf dem rechten.

Das Kamerabild läuft zuerst durch einen Hauptstrang, z. B. ResNet⁹, und danach weiter durch die restlichen Stufen des Netzes. Um das Wissen aus dem statischen Kamerabild zu integrieren, wird das statische Bild durch denselben Hauptstrang ("feature backbone" auf Englisch) geschickt und die Merkmalskarten ("feature pyramid" auf Englisch) des statischen Bilds mit denen des aktuellen Kamerabilds zusammengeführt. In unserer Implementierung des Hauptstrangs hat dieser keine separaten Parameter für das statische und das zu analysierende Bild. Zusätzliche Netzparameter ergeben sich bei der Einbeziehung des statischen Bildes nur durch die gewichtete Addition der Merkmalskarten. Die Architektur des Netzes ist in Abbildung 22 dargestellt.

Ein neuronales Netz wird üblicherweise mit vielen Kamerabildern verschiedener Perspektiven trainiert. Durch die Verwendung eines statischen Bilds ist es möglich, jede Kamera im Betrieb durch ihr eigenes statisches Bild zu spezialisieren und für ihre eigene Perspektive zu optimieren. Im Idealfall braucht die jeweilige Kamera weder ein gesondertes Training noch individuelle Trainingsdaten.

Statt das statische Bild explizit in der Architektur zu berücksichtigen, könnte man es auch zusammen mit dem Kamerabild in das Netz leiten. Statt eines 3-Kanal-Bildes wird beispielsweise ein 6-Kanal-Bild als Eingabe für das Netz benutzt. Dadurch müsste die doppelte Datenmenge prozessiert werden, wenn man die Auflösung der Bilder nicht verringern will. Das Netz wäre dann eventuell nicht mehr echtzeitfähig. Durch den hier gewählten Ansatz muss das Netz nur einmal mit dem statischen Bild initialisiert werden. Die dabei berechneten Merkmalskarten können für die Fusion mit denen des aktuellen Bilds gespeichert werden.

⁸ D. Bolya, C. Zhou, F. Xiao, Y. J. Lee: "YOLACT: Real-time Instance Segmentation", IEEE/CVF International Conference on Computer Vision, 9156 (2019)

⁹ K. He, X. Zhang, S. Ren, J. Sun: "Deep Residual Learning for Image Recognition", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (2016)




Abbildung 22: Die Architektur unserer wissensbasierten Objekterkennung YOLACT 2. Das statische und das zu prozessierende Bild durchlaufen denselben Hauptstrang mit denselben Netzparametern (Zeichnung übernommen und angepasst aus [2]).

Alternativ kann aus dem zu analysierenden und dem statischen Bild eine Differenz berechnet werden um diese dann als Eingabe für das Netz zu benutzen. Allerdings treten hier direkt Probleme mit unterschiedlichen Beleuchtungssituationen auf. Vor allem im Außenbereich hängen die Lichtverhältnisse und der Schattenwurf stark vom Wetter ab. Aber auch in einer Tiefgarage hat man Probleme mit den Autoscheinwerfern, die lokal die Szene beleuchten. Durch unseren Ansatz erhält das Netz die Möglichkeit, den Umgang mit unterschiedlichen Lichtverhältnissen selbst zu beherrschen.

Die Implementierung der Netzarchitektur wurde im Berichtszeitraum abgeschlossen. Erste Tests mit Realdaten aus einem Kundenprojekt wurden bereits durchgeführt und müssen im nächsten Schritt analysiert werden. Des Weiteren ist eine Optimierung der Hyperparameter geplant, wie zum Beispiel die Auswahl der Merkmalskarten zur Fusion der beiden Bilder.

Stand der Arbeiten (31.12.2022)

In diesem Arbeitspaket beschäftigt sich Valeo mit der Fußgängererkennung mittels statisch montierter Kameras. Diese sind z. B. an Wänden von Parkhäusern montiert, um das Einparken der Autos von außen zu steuern ("Automated Valet Parking", AVP). Als "Wissen" für das Netz wird ein Bild der jeweiligen Kamera ohne jegliche zu detektierende Objekte verwendet.

Die Integration von Wissen wurde auf Basis des Netzes "YOLACT" ("You Only Look At Coefficients") implementiert und in das KI-Wissen-Projektarchiv¹⁰ bei Gitlab hochgeladen. Es wurde die öffentlich erhältliche Implementierung "Yolact minimal"¹¹ als Grundlage verwendet. Die

¹⁰ <https://gitlab.com/ki-wissen/tp1/ap1.2/valeo-network-with-static-images>

¹¹ https://github.com/feiyuhuahuo/Yolact_minimal

Integration in den Demonstrator steht noch aus. Eine Dokumentation in Gitlab und Confluence ist vorhanden.

Für eine robuste Implementierung ist es wichtig, das Netz nicht nur mit simulierten Daten zu testen. Daher wurden im Berichtszeitraum Realdaten für das Training des Netzes auch auf dem Valeo-Firmengelände in Kronach aufgenommen. Vor allem aufgrund des Bedarfs an *leeren* Kamerabildern konnte nicht auf bestehende Daten zurückgegriffen werden. Abbildung 23 zeigt als Beispiel ein Kamerabild mit zu detektierenden Personen und Fahrzeugen und das dazugehörige leere Bild.



Abbildung 23: : (links) Bild einer statisch an der Wand montierten Kamera zur Detektion von Fußgängern und Fahrzeugen. (rechts) Gleiche Kameraperspektive, diesmal jedoch ohne zu detektierende Objekte.

Mit diesen Realdaten von verschiedenen Standorten und Kamertypen (Lochkamera, Fischaugenkamera) wurden erste Trainings durchgeführt und vorläufig evaluiert. Diese Arbeit ist noch nicht abgeschlossen, da auch weiterhin Daten aufgenommen werden, um Training und Evaluierung aussagekräftiger zu machen.

In der derzeitigen Implementierung laufen das Live-Kamerabild und das leere Bild durch denselben Hauptstrang und teilen sich dessen trainierte Parameter. Nach dem Durchlauf werden einige Merkmalskarten fusioniert und durchlaufen dann den Rest des Netzes. Für diese Fusion wurden verschiedene Möglichkeiten getestet. Eine gewichtete Addition mit zu trainierenden Koeffizienten erwies sich als numerisch instabil. Aktuell wird die Fusion durch eine 1x1-Faltung bewerkstelligt. Es wurde außerdem die Fusion verschiedener Merkmalskarten getestet. In Zukunft sollen noch weitere Hyperparameter getestet und das Netz optimiert werden.

Stand der Arbeiten (30.6.2023)

Valeo beschäftigt sich in diesem Arbeitspaket mit der Erkennung von Fußgängern durch statisch montierte Kameras. Solche Kameras werden zum Beispiel in Parkhäusern verwendet, um das Fahrzeug von außen gesteuert einzuparken ("Automated Valet Parking", AVP). Um die Erkennung zu verbessern, wird die Tatsache ausgenutzt, dass der Sichtbereich dieser Kameras immer gleich ist. Dadurch ist es möglich, ein Kamerabild ohne jegliche zu detektierende Objekte (leeres Parkhaus) dem Netz als "Wissen" zur Verfügung zu stellen.

In der ersten Version der Netzarchitektur werden das aktuelle Kamerabild und das leere Bild durch denselben Hauptstrang (Resnet¹²) geschickt und teilen sich dessen trainierte Parameter. Nach dem Durchlauf werden einige Merkmalskarten fusioniert und durchlaufen dann den Rest des Netzes ("background-aware shared Resnet", BASR). Diese Architektur ist in Abbildung 24 dargestellt. Im aktuellen Berichtszeitraum wurde eine alternative Architektur umgesetzt: Das leere und das aktuelle Kamerabild haben jeweils einen eigenen Resnet-Hauptstrang mit eigenen trainierten Parametern ("background-aware individual Resnet", BAIR), siehe Abbildung 25. Die Fusion erfolgt in beiden Fällen durch eine 1x1-Faltung.




Abbildung 24: "Background Aware Shared Resnet" (BASR). Das statische und das aktuelle Kamerabild laufen durch denselben Hauptstrang. (Zeichnung angepasst aus ¹³.)




Abbildung 25: "Background Aware Individual Resnet" (BAIR). Das statische und das aktuelle Kamerabild durchlaufen separate Hauptstränge. (Zeichnung angepasst aus 4.)

¹² K. He, X. Zhang, S. Ren, J. Sun: "Deep residual learning for image recognition", Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), 770 (2016)

¹³ D. Bolya, C. Zhou, F. Xiao, Y. J. Lee: "YOLACT: real-time instance segmentation", IEEE/CVF International Conference on Computer Vision, 9156 (2019)

Das Netz wurde mit Realdaten aus einem Kundenprojekt trainiert und evaluiert. Die Anzahl und Art der fusionierten Merkmalskarten aus den beiden Hauptsträngen wurden als Hyperparameter behandelt und durch mehrere Trainings optimiert. Es hat sich gezeigt, dass bei BASR die Fusion der Merkmalskarten C4 und C5 (vgl. Abbildung 24) die besten Ergebnisse liefert, bei BAIR hingegen die Fusion von C3, C4 und C5. Die Ergebnisse dieser beiden Netze zeigt Tabelle 6.

Tabelle 6: Vergleich der Netze Background Aware Shared Resnet (BAST) und Background Aware Individual Resnet (BAIR).

	minimal umgebendes Rechteck		Maske	
	Sensitivität	Mittl.Relevanz	Sensitivität	Mittl. Relevanz
YOLACT	69,2 %	63,5 %	59,8 %	53,4 %
YOLACT-BASR	70,7 %	64,5 %	61,0 %	54,2 %
YOLACT-BAIR	71,5 %	66,1 %	60,6 %	54,2 %
Verbesserung BASR	1,5 %	1,0 %	1,2 %	0,8 %
Verbesserung BAIR	2,3 %	2,6 %	0,8 %	0,8 %

Die Verwendung eines statischen Bildes als a priori-Wissen zeigt durchgehend Verbesserungen der Sensitivität und der mittleren Relevanz (Fläche unter der Relevanz-Sensitivität-Funktion) gegenüber dem Netz ohne statisches Bild, sowohl für die Bestimmung des minimal umgebenden Rechtecks als auch der Maske. BAIR liefert bessere Ergebnisse als BASR (außer für die Sensitivität der Maske). Besonders gute Ergebnisse ergeben sich für die Sensitivität (+2,3 %) und die mittlere Relevanz (+2,6 %) des minimal umgebenden Rechtecks durch BAIR. Die Relevanz-Sensitivität-Kurve zeigt Abbildung 26.




Abbildung 26: Relevanz in Abhängigkeit der Sensitivität. Zum Vergleich ist außer der Klasse "Fußgänger" auch die Kurve der Klasse "Fahrzeug" dargestellt. Die gestrichelten Linien kennzeichnen verschiedene Konfidenzschwellen zur Berechnung (0,8; 0,6; 0,4; 0,2).

Für das hier entwickelte Netz wurde ein Patentantrag gestellt. ("Verfahren zum Auswerten eines Bildes einer Erfassungseinrichtung", 30. Januar 2023) Weiterhin wurde damit begonnen, das entwickelte neuronale Netz in den Demonstrator zu integrieren.

Stand der Arbeiten (31.12.2023)

In diesem Arbeitspaket arbeitet Valeo an der Erkennung von Fußgängern durch stationäre, fest an Wand oder Decke montierte Kameras. Ein Anwendungsfall dafür ist zum Beispiel das sogenannte "Automated Valet Parking" (AVP), bei dem Fahrzeuge durch eine externe Steuerung ohne Fahrer einparken. Der feste Sichtbereich der stationären Kameras wird zur Verbesserung der Fußgängererkennung ausgenutzt, indem ein Kamerabild ohne jegliche zu detektierende Objekte (leeres Parkhaus) als "Wissen" für das neuronale Netz genutzt wird.

Es wurden in der Vergangenheit bereits zwei verschiedene Netzarchitekturen implementiert und evaluiert. In einer Version werden das statische und das aktuelle Kamerabild durch denselben Hauptstrang geleitet, in der anderen Version haben beide Bilder einen eigenen Hauptstrang mit einem eigenen Satz zu trainierender Parameter. In beiden Architekturen werden so Merkmalskarten für beide Bilder erstellt und dann fusioniert.

Um eine vereinheitlichte Beschreibung und damit eine Vergleichbarkeit mit anderen Ansätzen zu erreichen, wurde für die hier umgesetzte Architektur ein sogenanntes Entwurfsmuster entwickelt (Abbildung 27), wie das im Bereich der Softwarearchitektur bereits etabliert ist. Dazu wurde die Nomenklatur der Veröffentlichung von Bekkum et al.¹⁴ zugrunde gelegt. Der linke graue Kasten beschreibt das Training, der rechte die Inferenz. Für den Prozeß des Trainings sind die

¹⁴ van Bekkum et al.: "Modular design patterns for hybrid and reasoning systems: a taxonomy, patterns and use cases", Appl. Intell. 51, 6528 (2021)

Kamerabilder die Daten, die die Instanz für die statistische Methodik des Netzes darstellen. In der hier entwickelten hybriden Architektur kommt für den symbolischen, wissensbasierten Anteil das leere Bild ohne zu detektierende Objekte als weitere Instanz hinzu. Im Prozeß des Trainings wird ein Modell für die Fußgängererkennung generiert, das wiederum für den Prozeß der Inferenz verwendet wird. Dazu werden abermals die Daten der Kamerabilder als statistische Instanz und das leere Bild der jeweiligen Kamera als symbolische Instanz verwendet. Das Ergebnis dieses Prozesses sind dann symbolische Instanzen wie zum Beispiel minimal umgebende Rechtecke für die Objekte oder die semantische Segmentierung des Kamerabilds.




Abbildung 27: Entwurfsmuster für das entwickelte hybride neuronale Netz.

Die Hyperparameter der bereits fertiggestellten Architekturen wurden weiter optimiert. Das Netz wurde in den zur Verfügung gestellten Demonstrator fertig integriert und in das Projektarchiv auf Gitlab hochgeladen. Die Umsetzung Evaluierung des neuronalen Netzes innerhalb des Demonstrators führte jedoch (wie auch bei anderen Projektpartnern) zu Problemen, weshalb die finale Evaluierung des Ansatzes unabhängig vom Demonstrator mit Realdaten durchgeführt wurde. Für die minimal umgebenden Rechtecke konnte die Sensitivität um 2,3 % gegenüber dem Referenznetzes (YOLACT¹⁵) auf 71,5 % verbessert werden. Die mittlere Relevanz verbesserte sich um 2,6 % auf 66,1 %.

Das Diagramm links in Abbildung 28 stellt die Methodik des hier entwickelten Netzes zur Wissensintegration dar. Es wurde auf Weltwissen zurückgegriffen und dieses Wissen in die Architektur integriert. Das rechte Diagramm fasst die Resultate zusammen. Durch den hier entwickelten Ansatz konnte die Robustheit und damit auch die Zuverlässigkeit der für das autonome Fahren wichtigen Fußgängererkennung verbessert werden. Darüber hinaus erlaubt das integrierte Wissen, die vorhandenen Trainingsdaten effizienter zu nutzen, da mit gleichem Datenbestand bessere Ergebnisse erzielt werden.

¹⁵ D. Bolya, C. Zhou, F. Xiao, Y. J. Lee: "YOLACT: real-time instance segmentation", IEEE/CVF International Conference on Computer Vision, 9156 (2019)



Abbildung 28: : Methodik (links) und Ergebnisse (rechts) des entwickelten Netzes.

Stand der Arbeiten (31.3.2024)

In diesem Arbeitspaket beschäftigt sich Valeo mit der Objekterkennung durch stationäre (an Wand oder Decke montierte) Kameras. Diese Kameras haben einen unveränderlichen Sichtbereich, wodurch sich ein leeres Bild - ohne zu detektierende Objekte - als "Wissen" zur Verbesserung der Objekterkennung nutzen lässt.

Im letzten Berichtszeitraum wurden weitere Testtrainings zur Hyperparameteroptimierung durchgeführt, die jedoch zu keinen wesentlichen Verbesserungen gegenüber den zuletzt berichteten Ergebnissen brachten. Die Ergebnisse des Arbeitspakets wurden auf der Abschlussveranstaltung des Projekts am 21. März in Frankfurt am Main als Poster präsentiert.

3.1.1.3 AP1.3 Physikalische und mathematische Gesetzmäßigkeiten

Aufgaben von Valeo

- Formalisierung von physikalischem Wissen
 - Für die Objekterkennung in AP1.1
 - Für die Eigendiagnose in AP1.2

Stand der Arbeiten (30.6.2021)

In diesem Berichtszeitraum wurden zunächst im Einklang mit den Arbeiten im AP1.1 verschiedenen Quellen für geometrische Modelle der zu erkennenden Objekte identifiziert. Dabei wurden öffentliche Datensätze mit sogenannten CAD-Modellen (Abk. für Computer-Aided Design) ermittelt. Diese CAD-Modelle sind zumeist eher realitätsfern, was deren Eignung für die Wissensintegration infrage stellt. Alternativ wurde die Möglichkeit ermittelt, geometrische Modelle aus vorhandenen Datensätzen der 3D-Objektdetektion zu extrahieren. Auch dieses Verfahren soll in Zukunft weiter untersucht werden.

Zusätzlich zu den genannten Arbeiten hat Valeo sich aktiv an den Regeltreffen beteiligt.

Stand der Arbeiten (31.12.2021)

Die laufenden Forschungsarbeiten von Valeo in AP1.1 und AP1.2 fokussieren sich auf Welt- und Expertenwissen. Im Gegensatz zu den Planungen der Vorhabensbeschreibung befasst sich Valeo nicht mehr mit physikalischem Wissen. Die entsprechenden Arbeiten werden daher in Absprache mit der TP1-Leitung unter AP1.4 dargelegt.

3.1.1.4 AP1.4 Welt- und Expertenwissen

Aufgaben von Valeo

- Formalisierung von Weltwissen
 - Für die Objekterkennung in AP1.1
 - Für die Eigendiagnose in AP1.2

Stand der Arbeiten (30.6.2021)

Valeo hat an zwei Regeltreffen vom AP1.4 teilgenommen, in denen die Formalisierungen der Straßenverkehrsvorschriften als System deontischer Logik besprochen wurde. Valeo hat dabei aktiv seine Erfahrung zur Entwicklung automatisierter Fahrfunktionen eingebracht.

Stand der Arbeiten (31.12.2021)

Im Rahmen des AP1.4 wurden die Arbeiten zur Integration von Welt- und Expertenwissen aus dem AP1.1 aufgegriffen. Die Formalisierung von Weltwissen, in unserem Fall der modellhaften Repräsentationen von Personenkraftwagen, wurde in AP1.1 jedoch noch nicht abgeschlossen. Im vorliegenden Berichtszeitraum hat Valeo zunächst verschiedene Repräsentationen ermittelt und eine Entscheidung für den Startpunkt der Arbeiten getroffen. Im nächsten Schritt sollen die Objektmodelle zunächst mithilfe von Gaußschen Mischverteilungen formalisiert werden. Während die Arbeiten in AP1.1 fortlaufen, soll im Rahmen dieses AP1.4 die anderen möglichen Formalisierungen bereits vorbereitet werden. Hier sind zum Beispiel die Repräsentationen als Punktwolke oder Gitternetz zu nennen.

Stand der Arbeiten (30.6.2022)

Im Rahmen des AP1.4 wurden die Arbeiten an verschiedenen Wissensrepräsentationen für Kraftfahrzeugmodelle fortgesetzt. Dies bildet die Basis für die laufenden Arbeiten in AP1.1.




Abbildung 29: Gaussian Mixture Models für Personenkraftwagen extrahiert aus dem nuScenes Datensatz mit einem relativen Sensorwinkel von $-\pi/2$ (Automobil von hinten) auf dem linken Bild und einem relativen Sensorwinkel von $\pi/4$ (Automobil von der Seite) auf dem rechten Bild.

Es wurden Gaussian Mixture Models und dichte Punktwolken als Repräsentationen bestimmt. In Abbildung 29 sind beispielhaft zwei Gaussian Mixture Models für einen bestimmten relativen Sensorwinkel abgebildet, die aus dem nuScenes Datensatz extrahiert wurden. Zu sehen sind die Konfidenzellipsen der einzelnen Gauß-Verteilungen, so wie man es auch aus dem zweidimensionalen Anwendungsfall kennt.

Für eine Repräsentation als dichte Punktwolke wurden CAD-Modelle aus dem ShapeNet⁴ Datensatz gerendert. In Abbildung 30 ist eine solche Punktwolke aus zwei verschiedenen Blickwinkeln zu sehen.



Abbildung 30: Gerenderte dichte Punktwolke eines CAD Modell aus dem ShapeNet¹⁶ Datensatz. Das linke Bild zeigt die Vogelperspektive, das rechte Bild die Seitenansicht.

Für die Weiterführung der Arbeiten ist die Entwicklung weiterer Repräsentationen geplant. Im nächsten Schritt sollen die eine begrenzte Distanzfunktion mit Vorzeichen („truncated signed distance function“ auf Englisch) in einem voxelisierten Ansatz umgesetzt werden.

Darüber hinaus beteiligte sich Valeo aktiv an den regelmäßigen Telefonkonferenzen sowie an dem zweiten TP1 Workshop am 14. und 15. Juni 2022 in München.

¹⁶ Chang, Angel X., et al. "Shapenet: An information-rich 3d model repository." arXiv preprint arXiv:1512.03012 (2015)

Stand der Arbeiten (31.12.2022)

Im Rahmen des AP1.4 wurden in diesem Berichtszeitraum die Arbeiten an der Erstellung eines konzeptuellen Datensatzes aufgenommen. Dieser bildet die Basis für den in Arbeitspaket 1.1 neu vorgestellten Ansatz. Hierfür wurden die Objekte gemäß der Anzahl der Punkte gefiltert und sortiert. Anschließend wurden die übrigen Objekte nach ihrem relativen Sensorwinkel aufgeteilt. Dadurch wurde eine Datenbasis konzeptueller Objekte erstellt. Für jedes Objekt im originalen Datensatz wurde dann das passende konzeptuelle Objekt nach der Chamfer Distanz ermittelt und das originale Objekt durch das entsprechende konzeptuelle Objekt ersetzt. In Abbildung 31 ist solch eine Punktwolke zu sehen.




Abbildung 31: Ausschnitt aus einer Punktwolke aus dem NuScenes Datensatz . Weiße Punkte gehören zur ursprünglichen Punktwolke. Blaue Boxen markieren die Objekte. Lila Punkte wurden aus der konzeptionellen Datenbasis in die Punktwolke eingefügt.

Darüber hinaus beteiligte sich Valeo an den regelmäßigen Telefonkonferenzen.

Stand der Arbeiten (30.6.2023)

In diesem Berichtszeitraum wurden im Rahmen von AP1.4 Polygone erstellt, welche den gültigen Bereich zum Einfügen von Objekten bei der Ground Truth Sampling Augmentierungsmethode (siehe AP1.1) kennzeichnen .

Darüber hinaus hat Valeo an den Telefonkonferenzen teilgenommen.

Stand der Arbeiten (31.12.2023)

In diesem Berichtszeitraum wurden im Rahmen von AP1.4 untersucht, ob die Semantik öffentlicher Datensätze geeignet ist den gültigen Bereich zum Einfügen von Objekten bei der Ground Truth Sampling Augmentierungsmethode (siehe AP1.1) zu bestimmen. Hierzu wurde aus der Punktwolken-Semantik des nuScenes Datensatzes 2D Birdview Maps mit fester Pixelgröße erstellt. Darüber hinaus hat Valeo an den Telefonkonferenzen teilgenommen.

Stand der Arbeiten (31.3.2023)

Valeo hat im letzten Berichtszeitraum die Arbeiten in AP1.4 abgeschlossen. Aus diesem Grund hat sich Valeo in diesem Berichtszeitraum auf organisatorische Aufgaben beschränkt.

3.1.1.5 AP1.5 Vernetzung von Wissensrepräsentationen

Aufgaben von Valeo

- Vereinheitlichte Formalisierung von Wissen
 - Vereinheitlichung von Formalisierungsansätzen zu Sensorstöreinflüssen
 - Vereinheitlichung von Formalisierungsansätzen zu Objektmodellen

Stand der Arbeiten (30.6.2021)

Valeo konzentriert sich in diesem Arbeitspaket auf die Vereinheitlichung und Formalisierung von Störeinflüssen auf die Leistungsfähigkeit von Lidar-Sensoren. Mit der optischen Dejustierung aufgrund von Alterungsprozessen wurde ein erster Störeinfluss identifiziert und dessen Analyse aufgenommen.

Des Weiteren behandelt dieses Arbeitspaket die Vernetzung von formalisierten Wissen aus den Arbeitspaketen 1.1 bis 1.3. In dieser frühen Projektphase sind die Wissensformalisierungen in den benannten Arbeitspaketen noch nicht weit genug fortgeschritten für eine sinnvolle Vernetzung.

Stand der Arbeiten (31.12.2021)

In diesem Arbeitspaket untersucht Valeo die optische Dejustierung der Sender- und Empfangseinheit von LiDAR-Sensoren. Dies ist ein typischer Alterungseffekt. Die Detektion von Alterungseffekten ist wichtig, um die Zuverlässigkeit von Sensordaten beurteilen zu können. Das auf die Falschausrichtung bezogene Wissen wird von Valeo in AP1.2 erarbeitet und an AP1.5 weitergeleitet. Für eine optimale Austauschbarkeit dieses Wissens sollen die Parameter in der Auszeichnungssprache YAML dargestellt werden. In der Zukunft soll das Wissen mit den laufenden Arbeiten von Valeo in AP1.1 vereinheitlicht werden.

Stand der Arbeiten (30.6.2022)

In diesem Arbeitspaket soll eine möglichst große Einheitlichkeit der Darstellung des integrierten Wissens mit einer leichten Austauschbarkeit erreicht werden. In AP1.1 besteht das von Valeo genutzte Wissen aus dreidimensionalen Punktwolken, die ein Objekt beschreiben (Koordinaten x,y,z). In AP1.2 nutzen wir zweidimensionale Kamerabilder (Koordinaten x,y, Farben rot, gelb, grün). Eine Fusion von Kamera- und Lidardaten ist bei Valeo jedoch innerhalb von KI Wissen nicht geplant. Daher ist auch eine Fusion der entsprechenden Wissensbausteine momentan nicht sinnvoll.

Daher untersucht Valeo die Nutzbarkeit von Punktwolken zur Repräsentation der statischen Umgebung für den Anwendungsfall in AP1.2. Diese Punktwolke wird in den Arbeiten zu AP2.2 erstellt und ist als Ergebnis für das Ende des aktuellen Berichtszeitraums geplant. Anschließend

ist eine Nutzung dieser Punktwolke in AP1.2 zu prüfen. Die in AP1.5 geplante Vernetzung von Wissensrepräsentation kann erst als letzter Schritt dieser Kette erfolgen.

Stand der Arbeiten (31.12.2022)

In diesem Arbeitspaket geht es darum, eine möglichst große Einheitlichkeit der Darstellung des integrierten Wissens und dessen möglichst leichte Austauschbarkeit zu erreichen. So soll das Wissen sowohl als Eingabe in Teilprojekt 1, als auch für die Plausibilisierung in Teilprojekt 3 Verwendung finden können.

In den Arbeitspaketen 1.1 und 3.5 wird ein CAD-Modell mit der prädierten Punktwolke des Objektes verglichen. In AP 1.1 sollte durch diesen Vergleich ein Fehlerterm für das Training berechnet werden, in AP 3.5 wird dadurch eine Objektprädiktion auf Plausibilität überprüft. Hierbei hat sich die Schwierigkeit gezeigt, eine geeignete Repräsentation und ein dazugehöriges Maß für die Ähnlichkeit zu finden. Üblich für den Vergleich von Punktwolken sind hier die Hausdorff-Metrik, der Chamfer-Abstand oder die Wasserstein-Metrik (auch "earth mover's Metrik" genannt). Bisher war keines der Verfahren zufriedenstellend, was die Notwendigkeit einer Homogenisierung von Punktwolken deutlich macht.

In den Arbeitspaketen 1.2 und 3.5 wird das Kamerabild einer leeren Szenerie, welches keine zu detektierenden Objekte enthält, als Wissen benutzt, um die Objektdetektion per Kamera zu verbessern. Hier zeigt sich, dass das leere Bild von photometrischen Parametern wie z. B. Helligkeit, Kontrast, Sättigung und Farbton beeinflusst wird, die aber keine Auswirkung auf den eigentlichen Wissensgehalt haben. Trotzdem haben diese photometrischen Variationen einen nicht unerheblichen Einfluss auf das Ergebnis der Algorithmen.

Um eine einheitliche Darstellung des leeren Bildes zu erreichen, wurden verschiedene Normierungsverfahren ausprobiert. Eine Möglichkeit besteht darin, die drei Farbkanäle (rot, gelb, grün) getrennt voneinander mit ihrem jeweiligen Mittelwert und Standardabweichung zu normieren. Alternativ kann das Bild vorher in ein Graustufenbild umgewandelt und dann normiert werden. Erste Versuche zu den Auswirkungen auf die Algorithmen in AP 3.5 wurden gemacht und sollen auch für AP 1.2 noch durchgeführt werden. Des weiteren sollen ähnliche Normierungen noch in anderen Farbräumen als RGB (rot, gelb, grün), z. B. im HSV-Farbraum (Farbwert, Sättigung, Helligkeit), getestet werden.

Die erarbeiteten "Knowledge Building Blocks" (KBB015, KBB033) wurden in Confluence dokumentiert und im Conjoint White Paper beschrieben.

Stand der Arbeiten (30.6.2023)

Valeo arbeitet an der Vereinheitlichung von Lidar-Punktwolken und Kamerabildern. Bei den Kamerabildern wurden Normierungsverfahren getestet, um das enthaltene "Wissen" unabhängig von technischen Parametern der Aufnahme, wie z. B. der Belichtung, zu machen. Ebenfalls stellen in vielen Fällen Wettereinflüsse - wie z. B. starke Schatten bei Sonnenschein versus kein Schatten bei Bewölkung - Variationen des Bildes dar, die aber den eigentlichen Informationsgehalt verschleiern. Es wurden deshalb Ansätze über die Normierung der Parametern in verschiedenen Farbräumen ausprobiert. Die Arbeiten bezüglich den APs 1.1 und 3.5 wurden aufgrund der nicht zufriedenstellenden Ergebnissen der Verfahren und Metriken zum Vergleich von Punktwolken, bzw.

Objektmodellen beendet. Der Fokus wurde jetzt auf die Verbesserung der Detektionen in statischen Umgebungen gelegt. Hierbei wird das Wissen der Umgebung in Form eines Gültigkeitspolygons verwendet, um das Einfügen von Objekten bei der Augmentierung in die LiDAR Punktwolken realistischer durchzuführen. So werden Objekte nur innerhalb des durch das Polygon definierten Bereichs eingeführt. Auch ein Filtern der Detektionsergebnisse ist durch das Wissen um das Gültigkeitspolygon möglich. Es wird untersucht, ob im Falle mehrerer statischer Szenarien die Gültigkeitspolygone für eine Verbesserung des gemeinsamen Trainings genutzt werden können, inwieweit eine Reduktion der Trainingsdaten durch die so verbesserte Augmentierung möglich ist und inwieweit durch das Polygon als apriori Wissen eine Vereinheitlichung der verschiedenen statischen Szenarien möglich ist, sodass keine gelabelten Daten eines neuen Szenarios benötigt werden, um zufriedenstellende Ergebnisse zu erzielen.

Stand der Arbeiten (31.12.2023)

Ziel dieses Arbeitspaketes ist es, das dem Netz zur Verfügung zu stellende Wissen möglichst allgemein verwendbar darzustellen. Valeo arbeitet hier an der Vereinheitlichung von Lidar-Punktwolken und Kamerabildern.

Zur Erkennung von Fußgängern mittels stationärer Kameras an Wänden oder Decke wird als "Wissen" ein leeres Kamerabild der jeweiligen Kameraperspektive ohne zu detektierende Objekte verwendet. Hier sind technische Parameter, wie zum Beispiel Unterschiede in Helligkeit, Kontrast, Sättigung und Farbwert ein Problem. Um diese Probleme zu minimieren und das leere Kamerabild möglichst universal verwenden zu können, wurden verschiedene Normierungen getestet. Abbildung 32 zeigt Beispiele dafür. Die besten Ergebnisse wurden mit einem graukonvertierten, normierten Bild erzielt. Hier ist die Ähnlichkeit (bestimmt mit dem Index struktureller Ähnlichkeit) zwischen einem Bild und photometrisch zufällig gestörten Versionen desselben Bilds am Besten.




Abbildung 32: (links oben) Ein "leeres" Bild, mit dessen Hilfe in einem anderen Bild ein Fußgänger detektiert werden soll. (links unten) Das gleiche Bild, jedoch mit zufälligen Abweichungen in Helligkeit, Kontrast, Sättigung und Farbwert. In der zweiten Spalte wurden die Bilder aus der ersten Spalte normiert (alle drei Farbkanäle separat), in der dritten Spalte in Graustufen umgewandelt und in der vierten Spalte die Graustufenbilder normiert.

Im Bereich der Lidar-Punktwolken wurde die Verbesserung der Detektionen in statischen Umgebungen erfolgreich abgeschlossen. Das Gültigkeitspolygon wurde verwendet und mit verschiedenen Varianten experimentiert. Es wurde untersucht, ob im Falle mehrerer statischer Szenarien die Gültigkeitspolygone für eine Verbesserung des gemeinsamen Trainings genutzt werden können und inwieweit durch das Polygon als *a priori* Wissen eine Vereinheitlichung der verschiedenen statischen Szenarien möglich ist, sodass keine gelabelten Daten eines neuen Szenarios benötigt werden, um zufriedenstellende Ergebnisse zu erzielen. Trotz einer Reduzierung der gelabelten Trainingsdaten auf 25% konnten Detektionsergebnisse erzielt werden. Diese fielen jedoch schlechter aus als mit 100% der Daten. Das Gültigkeitspolygon verbesserte die Ergebnisse in allen Fällen.

Stand der Arbeiten (31.3.2024)

Die Arbeiten in AP 1.5 sind schon im letzten Berichtszeitraum abgeschlossen worden. Ein Teil der Ergebnisse ist in ein Poster eingeflossen, das am 21. März auf der Abschlußveranstaltung des Projekts in Frankfurt am Main präsentiert wurde.

3.1.2 TP2: Wissensextraktion

Tabelle 7: Struktur von TP2

TP/AP	Titel	Leitung
TP2	Wissensextraktion	Continental
AP2.1	Konzeptextraktion aus dem Modell	Alexander Thamm
AP2.2	Vorhersagen von Konzepten	Fraunhofer IAIS
AP2.3	Ableitung neuen Wissens	Fraunhofer IAIS

3.1.2.1 AP2.2 Vorhersage von Konzepten

Aufgaben von Valeo

- Entwicklung von Situationsbeschreibungen
 - Unterstützung bei der Identifikation relevanter Situationen
 - Unterstützung bei der Bewertung von Situationen hinsichtlich Zuverlässigkeit und Nachvollziehbarkeit
 - Identifikation und Evaluierung von Methoden zur Generierung von Output-Wissen
- Entwicklung einer Situationserkennung
 - Spezifikation der Anforderungen für eine Situationserkennung
 - Modifikation der Objekterkennung aus AP1.1 in Bezug auf die Anforderungen
 - Modifikation der Sensoreigendiagnose aus AP1.2 in Bezug auf die Anforderungen

Stand der Arbeiten (30.6.2021)

Die unterschiedliche Reflektivität von Materialien im Straßenverkehr ist für Lidar-Sensoren eine generelle Herausforderung. Zur Detektion von schwach reflektiven Objekten benötigt man eine hohe Integrationszeit. Diese ist vergleichbar mit der langen Belichtungszeit von Fotokameras. Eine hohe Integrationszeit führt jedoch bei hoch reflektiven Objekten zu mindestens zwei Problemen. Erstens werden einzelne Pixel oft übersättigt. Zweitens tritt ein Übersprechen der überbelichteten Pixel auf benachbarte Pixel auf. Dieses Übersprechen ist ähnlich einer Blendung einer Fotokamera, wenn man beispielsweise die Sonne ohne entsprechenden Filter aufnimmt.

Im AP2.2 untersuchen wir diese Fragestellung anhand der Nahfeld-Lidar-Sensoren von Valeo. Diese Sensoren wenden eine Frequenzmodulation auf das ausgesandte Licht an und bestimmen die Distanzen über eine Phasenverschiebung des empfangenen Signals.

Durch die Funktionsweise des Nahfeld-Lidar-Sensors wirken sich übersättigte Pixel als Fehler in den Distanzen und Amplituden benachbarter Pixel aus. Problematisch wird dies beispielsweise bei der Erkennung von Personen im Nahbereich zu einem hoch reflektiven Schild. Die Distanzen der Person werden auf die Distanzen des Schildes geschoben. Dieses Verhalten würde beim Training oder der Anwendung von KI-Methoden zu Problemen führen.

Die Problematik der Übersättigung wurde in einer Reihe von Tests mit einem Dummy in Kindergröße, einem Schild mit zehnprozentiger Reflektivität und einem hoch reflektiven Schild untersucht (siehe Abbildung 33). Die Entfernungen sind in Millimeter dargestellt. Das linke Bild zeigt die optimale Referenz-Szene. Dabei wurde das hoch reflektive Schild abgedeckt, womit kein Übersprechen zu sehen ist. Für das mittlere Bild wurde die Abdeckung vom hoch reflektiven Schild entfernt. Der Einfluss der Überbelichtung auf den Dummy, die Wand hinter dem Schild und das Schild mit zehnprozentiger Reflektivität ist gut zu erkennen. Der Einfluss auf den Rest des Bildes liegt in einer Größenordnung von 100 mm, ist jedoch in der gewählten Farbskala schlechter zu erkennen. Weiterhin sind die überbelichteten Pixel auf dem mittleren Bild dunkelblau dargestellt.




Abbildung 33: Die optimale Distanzmessung mit einem Nahfeld-Lidar-Sensor (linkes Bild) weist im Falle von Überbelichtung einen Bereich mit falschen Detektionen auf (mittleres Bild). Der logarithmische Fehler zeigt klar den problematischen Bereich in der Bildmitte (rechtes Bild)

Innerhalb der übersättigten Pixel liegen Pixel deren ermittelter Übersättigungswert falsch negativ ist, und deswegen zu fehlerhaften Distanz-Rauschen führt. Bei genauerer Betrachtung fällt auf, dass die übersättigten Pixel zusammen mit den falsch-negativ übersättigten Pixeln eine Fläche deutlich größer als das Schild ausmachen. Auf dem rechten Bild ist der absolute Distanzfehler mit Hilfe einer logarithmischen Farbverteilung dargestellt. Dabei kann man den erwähnten Fehler auf dem ganzen Bild gut erkennen. Der Fehler im Übergang zur nächsten Periode kann dabei ignoriert werden.

Der blaue Streifen über dem Dummy im linken Bild ist ein Messfehler gemäß dem Funktionsprinzip des Nahfeld-Lidar-Sensors. Mit der festgelegten Modulationsfrequenz können nur Distanzen innerhalb einer Wellenlänge aufgelöst werden. Eine Lösung für dieses Eindeutigkeitsproblem liegt in der Verwendung von verschiedenen Modulationsfrequenzen.

Zusammenfassend wurden Effekte zur Überbelichtung von Nahfeld-Lidar-Sensoren untersucht. Im nächsten Schritt wird Valeo eine Formalisierung dieser Erkenntnisse erarbeiten.

Stand der Arbeiten (31.12.2021)

Im letzten Berichtszeitraum wurde von Valeo die beginnenden Arbeiten zur Kompensation eines Blooming-Effektes in den hauseigenen LiDAR-Sensoren berichtet. Bei dem untersuchten Blooming-Effekt kommt es aufgrund von überbelichteten Objekten zu einem optischen Übersprechen zwischen benachbarten Pixel.

Im Dezember 2021 wurde firmenintern der Bau unserer LiDAR-Sensoren organisatorisch neu strukturiert. Blooming-Effekte sind meist tief in der Funktionalität der Hardware verwurzelt, weshalb dieses Thema in Zukunft nicht mehr von den an KI Wissenbeteiligten Fachabteilungen untersucht wird. Daher widmet sich Valeo in Absprache mit der Leitung von AP2.2 nun dem neuen

Thema „Wissensextraktion durch Simulation im Anwendungsfall AVP (Akb. für „Automated Valet Parking“. AVP bietet in der Zukunft vollautomatisiertes Einparken als Dienstleistung. Autonomes Parken ist ein hochinnovatives Themenfeld, da dort in einer kontrollierten Umgebung ein hoher Automatisierungsgrad in relativ kurzer Zeit erreicht werden kann. Durch die Covid-19 Situation entstand im Berichtszeitraum eine Überbelastung der entsprechenden Entwickelnden mit gleichzeitigem Einstellungsstopp. Dies resultierte in einem Verzug der Arbeiten in AP2.2. Die entsprechenden Arbeiten sollen in den kommenden Berichtszeiträumen nachgeholt werden.

Die meisten konventionellen Fahrassistenzsysteme verfolgen einen regelbasierten Ansatz, wie beispielsweise der weit verbreitete Abstandsregeltempomat in vielen Serienfahrzeugen. Für dessen Prädiktionen werden Bilder einer Frontkamera mit Daten aus der Fahrzeugdynamik verschmolzen. Diese Vorhersagen werden verwendet, um das Bremsen oder Beschleunigen zu steuern. Neuere Systeme sind auf Ansätze gerichtet, die auf KI (Akb. für „künstlicher Intelligenz) basieren. Um eine akzeptable Leistung für datenbasierte KI Systeme zu erreichen sind enorme Datenmengen von hohen Qualität und Vielfalt nötig.

KI Systeme sind im Vergleich zu konventionellen Systemen mit einer neuen Komplexität in der Verifizierung und Validierung verbunden. Für die Fehlerbehebung von komplexen Systemen ist Rückverfolgbarkeit von entscheidender Bedeutung: die genauen Ursachen für Fehler müssen ermittelt werden. Diese Informationen werden üblicherweise für die Fehlerbehebung von Fahrerassistenzsystemen während der Entwicklungs- und Produktionsphase verwendet. Regelbasierte Algorithmen können die Fehler bis zu einzelnen Funktionen im Quellcode rückverfolgen. KI basierte Module hingegen bilden oft monolithische Blöcke, bei denen eine Zuordnung von fehlerhaftem Verhalten zu einem bestimmten Teil der KI nicht möglich ist. Die Fehlerbehebung erfolgt in der Regel durch eine Optimierung der KI mit den jeweiligen Daten aus problematischen Situation. Dieser Ansatz garantiert keine Verbesserung für die gesamte Klasse von Problemen, die dieser eine Fehler repräsentiert.

Valeo plant eine Verbesserung der Erkennungsleistung bestehender KI Systems durch die Identifikation der Klasse an problematischen Situationen, d. h. das Wissen über die genauen Ursachen des Versagens wird extrahiert. Dieses Wissen kann genutzt werden, um die Leistung des KI Systems zu verbessern. Beispielsweise wird die Architektur des KI Systems geändert und zusätzliche Verarbeitungsschritte in der Pipeline eingefügt.




Abbildung 34: Architektur zur Erstellung einer realistischen HD-Karte.

Der Prozess zur Erstellung einer realistischen HD-Karte erfordert viele Teilprozesse, wie auf Abbildung 34 dargestellt. Die Modellierung der realen Umgebung basiert auf den Daten eines LiDAR-Sensors mit 64 Detektionsebenen von Velodyne und vier Fischaugenkameras von Valeo. Der LiDAR-Sensor ist auf dem Dach des Testfahrzeugs montiert, während die Fischaugenkameras vorne, hinten und an den Seiten des Fahrzeugs montiert sind. Die Lagen der Sensoren wurden auf eine maximale Abdeckung des Sichtfeldes optimiert. Als Randbedingung müssen Tiefenschätzungen in hoher Entfernung und ausreichender Winkelauflösung erfolgen. Die starren Transformationen, welche die extrinsischen Beziehungen zwischen den Sensoren beschreiben, werden mit Hilfe der proprietären Kalibrieroutine von Valeo ermittelt.

Die Winkelauflösungen des LiDAR-Sensors führen zu einer dünnen Punktwolke. Dies kann zu Lücken im Sichtfeld führen, in denen keine Informationen zwischen aufeinanderfolgenden LiDAR-Punkten verfügbar sind. Eine dichte Darstellung der Umgebung ist für die Erstellung von realistischen HD-Karten von großer Bedeutung. Hierfür plant Valeo den Einsatz von SLAM-Algorithmen (Abk. für "Simultaneous Localization and Mapping"). Auf der Grundlage von Sensordaten erstellen SLAM-Algorithmen Karten der Umgebung und lokalisieren darin gleichzeitig das Ego-Fahrzeug.

Stand der Arbeiten (30.6.2022)

Die Kundenfunktion AVP kann ein entscheidender Zwischenschritt in Richtung autonomes Fahren nach SAE Level 5 sein. Im AVP fährt ein Auto in einer kontrollierten Umgebung ohne jeglichen Fahrer völlig autonom zwischen einer Abgabestelle und dem jeweiligen Parkplatz. In dieser kontrollierten Umgebung lassen sich überaus gut neueste KI Ansätze testen und weiterentwickeln.




Abbildung 35: Toolchain für die Simulationserstellung.

Eine AVP-Testumgebungen von Valeo befindet sich auf dem Parkplatz vor unserem Forschungsstandort in Kronach. Die Überwachung mit statischen Kameras ist ein Schlüsselfaktor für die Perzeption von AVP. Das Wahrnehmungssystem kann in bestimmten Situationen versagen und zu unerwünschten Ergebnissen führen. Beispielsweise können Fußgänger in der näheren Umgebung gefährdet werden. Unser Ziel ist es für AVP eine leistungsfähige Simulation zu entwickeln, welche Wissen über problematische Szenarien generiert.

Simulation ist die Nachahmung des Betriebs eines realen Prozesses oder Systems. Für den Anwendungsfall AVP können wir die Umgebungsmodelle der Simulationsumgebung entweder manuell oder teilautomatisiert erstellt werden (siehe Abbildung 35). Im manuellen Fall in Abbildung 36 messen dabei die Hauptmerkmale mit einem Tachymeter zur Erstellung eines 3D-Modells in dem 3D-Modellierungswerkzeug Blender. Die 3D-Modell-Assets mit den entsprechenden Texturen der Parkumgebung wurden in Autodesk Inventor und Blender erstellt (siehe rechtes Bild in Abbildung 36).




Abbildung 36: Tachymetermessungen und Simulationsumgebung in dSPACE Motion Desk.

Im teilautomatisierten Fall können die Modelle der Simulationsumgebung mit SLAM (Abkürzung für „simultaneous localization and mapping“, d.h. gleichzeitige Lokalisierung und Erstellung einer Karte) generiert werden, welches als Eingabe Punktwolken von einem Laserscanner und Bilder einer Kamera nutzt. Der Laserscanner gibt eine Punktwolke aus, in der jeder Punkt einem Oberflächenpunkt der Umgebung entspricht. Die Kamera liefert Farbinformationen zu diesem

Punkt. Nachdem eine statische 3D-Simulationsumgebung erstellt wurde, muss sie in ein spezielles Simulationswerkzeug importiert werden. In diesem Simulationswerkzeug können Umgebungselemente und Features erstellt werden. In Kollaboration mit dSPACE nutzen wir deren Werkzeug ModelDesk für die Generierung von Assets und Features und deren Werkzeug MotionDesk für die Simulationsvisualisierung.




Abbildung 37: LeGO-LOAM SLAM der Valeo-Anlagen und Bild der Valeo-Anlagen in Kronach.

Wir haben uns für LeGO-LOAM SLAM als Algorithmus entschieden (siehe Abbildung 37). Dieser verwendet als Betriebssystem Linux Ubuntu und als Framework ROS 1. Für die Aufnahme verwendeten wir einen Velodyne Lidar-Sensor mit 16 Kanälen. Dieser Lidar-Sensor wurde als Handheld-Gerät montiert, um den Sensor frei in verschiedene Richtungen zu bewegen. Als Recheneinheit wurde ein Nvidia Jetson Nano verwendet. Die erzeugte globale Punktwolke bildet eine detaillierte Referenzumgebung zur Erstellung eines 3D-Modells für die Simulation.



Abbildung 38: Implementierung einer simulierten Fischaugenkamera in dSPACE Motiondesk (linkes Bild), Ausgabe dieser Fischaugenkamera (Bild in der Mitte) und Aufnahme der entsprechenden realen Kamera (rechtes Bild).

Im nächsten Schritt wird das statische Umgebungsmodell in die Simulationswerkzeuge von dSPACE importiert. Das als Anwendungsfall gewählte AVP ist ein System, bei dem das fahrende Auto von Kamerasensoren beobachtet wird. Die Straße mit den entsprechenden Fahrspuren, dem Zebrastreifen, den Parkplatzlinien und das dynamische Szenario wurden im Simulationswerkzeug erstellt. Als Kamera wird eine Valeo Modell mit Fischaugenlinse verwendet (siehe Abbildung 38).

Stand der Arbeiten (31.12.2022)

Valeo hat sich im vorliegenden Berichtszeitraum intensiv mit der Erstellung und Validierung von Simulationsumgebungen beschäftigt. Als Testumgebung wurde dafür das Valeo Firmengelände am Standort in Kronach gewählt, da es sich hierbei auch um eine Testumgebung für unseren Anwendungsfall Automated Valet Parking (AVP) handelt. Simulationsmodelle der Testumgebung konnten bereits manuell erstellt werden, wobei wichtige Merkmalspunkte (Höhe, Tiefe, Länge) mit einem Tachymeter eingemessen werden und daraus ein 3D-Modell mit einem 3D-Modellierungstool erstellt wird.

Darüber hinaus hat Valeo im zurückliegenden Halbjahr auch Techniken zur halbautomatisierten Erstellung von Simulationsmodellen mittels der Fusion von Kamera und LiDAR Sensoren erprobt. Dabei werden als Eingabe die Punktwolken eines Laserscanners und die entsprechenden Kamerabilder benötigt. Für die LiDAR-zu-Kamera Sensorfusion muss die Sensorposition und Sensorausrichtung bekannt sein. Die Bestimmung der Sensorausrichtung wird von einem Beschleunigungssensor unterstützt. Um den Trajektorienpfad mit Positions- und Orientierungsinformationen zu erhalten, wird ein SLAM-Algorithmus (Simultaneous Localization And Mapping) verwendet.

Nachdem eine statische 3D-Simulationsumgebung erstellt wurde, muss sie in ein geeignetes Simulationstool importiert werden. In dieser Umgebung können dann wiederum virtuelle Sensoren erstellt und konfiguriert werden. Wir schlagen *Blender* und *CARLA Simulator* für die Sichtfeld-Sensor-Simulationsvisualisierung vor.




Abbildung 39: Toolchain für die Simulationsgenerierung

Manuelle Erstellung definierter Welten

Für die manuelle Erstellung von definierten Welten wurden die Abmessungen von Umgebungs-Punkten mit Tachymeter und Laser-Entfernungsmessgerät gemessen. Die 3D-Modell-Assets mit entsprechenden Texturen der Parking Umgebung wurden von AutoDesk Inventor und Blender erstellt.




Abbildung 40: Umgebungsmessungen und Simulationsumgebung in Unreal Engine 4.

Erstellung definierter Welten mit Kamera-Lidar-Sensor-Fusion

Simultaneous Localization and Mapping (SLAM) erfordert eine Punktwolke vom Laserscanner als Eingabe, um eine globale Punktwolke zu erstellen, in der jeder Punkt einem Oberflächen Punkt der Referenzumgebung entspricht, und es erfordert eine Inertial measurement unit (IMU), um die Ausrichtung zu berechnen (Yaw, Pitch, Roll). Wir haben LiO-SAM SLAM für den SLAM-Algorithmus gewählt. Es erfordert Linux Ubuntu als Betriebssystem und ROS als Framework. Für die Aufzeichnung verwenden wir einen Velodyne LiDAR-Sensor mit 16 Kanälen, der als Handgerät montiert war. Als Rechner kommt ein Nvidia Jetson Nano zum Einsatz. IMU Microstrain 3DM-GX5-25 zum Aufzeichnen von IMU-Daten und Raspberry Pi Camera v2.1 zum Aufzeichnen von Bildern.




Abbildung 41: Kamera-Lidar Sensor Fusion

Die SLAM-Auswertung der Daten des Beschleunigungssensors und des Laserscanners ergeben die Trajektorienpunkte mit den entsprechenden Werten für die Position (x, y, z), die Orientierung ($yaw, pitch, roll$) und den Aufnahmezeitstempel. Um die Punktwolke gemäß der Farbinformation aus den Kamerabildern zu kolorieren, müssen die Sensordaten zeitsynchronisiert werden. Die Aufzeichnungsfrequenzen der Sensoren unterscheiden sich dabei folgendermaßen: Kamera 30 fps, Lidar 10 Hz, IMU 500 Hz.




Abbildung 42: Architektur für die Synchronisierung von Sensordaten basierend auf Zeitstempel Informationen.

Für die LiDAR-Kamera Sensorfusion muss initial eine Kalibrierung der Sensoren durchgeführt werden. Bei der intrinsischen Kalibrierung der Kamera wurden die Brennweite, die optische Achse sowie die Verzerrungskoeffizienten bestimmt. Bei extrinsischer Co-Kalibrierung von LiDAR und Kamera wurde der relative Versatz der Sensorkoordinatensysteme bestimmt. Die LiDAR Punkte werden entsprechend dieses Versatzes in das Kamerakoordinatensystem transformiert und anschließend gemäß der intrinsischen Kameraparameter auf die Kamerabilder projiziert. Wenn sich die projizierten Punkte innerhalb von Bildern befinden, werden die Farbwerte den entsprechenden Punkten aus der Punktwolke zugewiesen.




Abbildung 43: Extrinsische Kalibrierung von Lidar und Kamera, projizierte Punkte auf das Bild

Simulation Datenerfassung und Sensor Einrichten

In der Entwicklung des Automated Valet Parking Systems verwendet Valeo als Kamerasensor die zweite Generation der Valeo Fischaugenkamera. Diese Kamera wurde als virtueller Sensor modelliert und kann an gewünschter Stelle in der Simulationsumgebung eingefügt werden.¹



Abbildung 44: Fischaugenkamera Bildausgabe: (links) in Blender auf globaler farbiger Punktwolke (mitte) in CARLA Simulator mit manuell erstelltem Umgebungsmodell (rechts) der realen Kamera

Stand der Arbeiten (30.6.2023)

Valeo hat sich im vorliegenden Berichtszeitraum weiterhin intensiv mit der Erstellung und Validierung von Simulationsumgebungen des Valeo Firmengeländes (Standort Kronach) beschäftigt. Im bisherigen Projektverlauf hatten wir bereits eine manuelle Methode (auf Tachymetermessungen beruhend) und eine halb-manuelle Methode (auf Kamera-LiDAR Fusion basierend) zum Einmessen der Simulationsumgebung entwickelt und eingesetzt. In diesem Zwischenbericht beschreiben wir zwei weitere Methoden, mit denen eine noch präzisere bzw. eine automatisierte Erstellung der Simulationsumgebung ermöglicht werden. Eine hohe Genauigkeit der Simulationsumgebung wurde auf Grundlage einer hochpräzisen, farbigen Punktwolke die mit dem professionellen Laserscannern Leica RTC 360 erstellt wurde erreicht. Um ein 3D-Modell aus der gescannten Punktwolke als Blaupause-Referenz zu erstellen, wurde anschließend das CAD-Programm *Autodesk Revit* als 3D Modellierungswerkzeug verwendet.

Andererseits können Modelle auch automatisch mit Photogrammetrie erstellt werden. Um ein Modell mit Photogrammetrie zu erstellen, müssen viele Bilder mit einer Drohne (DJI Mavic 2) oder/und einer Digitalkamera aufgenommen werden. Der so entstandene Bilddatensatz muss in ein Photogrammetrie-Tool wie *Reality Capture* importiert werden, das ein 3D-Modell mit Texturen als Ausgabe erstellt.

Nachdem eine statische 3D-Simulationsumgebung erstellt wurde, muss diese in ein Simulationstool importiert werden, in dem die Sensoreinstellungen erstellt werden können. Wir schlagen dSpace Aurelion und CARLA Simulator für die Visualisierung von Field-of-View Sensor Simulationen vor.




Abbildung 45: Toolchain für die Simulationsgenerierung

Halbautomatische Erstellung von definierten Welten

Für die halbautomatische Erstellung der benutzerdefinierten Welt wurde eine sehr dichte farbige Punktwolke der Umgebung mit einem Laserscanner (Leica RTC360) gemessen. Kommerzielle Laserscanner wie das eingesetzte Gerät von Leica können mit einer Reichweite von 0,5 m bis 130 m scannen und haben eine Genauigkeit von 2 mm innerhalb von 10 m. Der Laserscanner verfügt über ein Tool, mit dem mehrere Scans aus derselben Scanumgebung zu einem einzigen Scan fusioniert werden können. Für unsere Testumgebung wurden drei Einzelscans zusammengefügt.




Abbildung 46: Scannen der Kronach Teststrecke mit Leica Scanner. Punktwolke visualisiert in Cloud Compare

Auf Grundlage der Punktwolke wurden die 3D-Modell-Assets mit den entsprechenden Texturen der Umgebung in Autodesk Revit erstellt.





Abbildung 47: Erstellen einer 3D-Umgebung in Autodesk Revit

Erstellung von definierten Welten mit Photogrammetrie

Die Photogrammetrie benötigt Bilder von einer Drohne und/oder Kamera als Input für die Erstellung eines 3D-Modells. Mit dem Tool Reality Capture werden die Scandaten automatisch registriert, in einem Koordinatensystem zusammengefügt, bereinigt und analysiert. Der Bilddatensatz von 380 Bildern wurde mit der Drohne Mavic Air 2 aufgenommen. Der Photogrammetrie-Prozess mit Reality Capture beginnt mit der Bildausrichtung als Prozess des Abgleichs eines Bildes mit einem anderen, und es wird eine dünne Punktwolke in der 3D-Ansicht erstellt.





Abbildung 48: Bildausrichtung in Reality Capture und daraus resultierende dünne Punktwolken und Netzerstellung

Nach der Bildausrichtung besteht der nächste Schritt darin, aus der registrierten Punktwolke ein 3D-Modell zu erstellen. Das Endprodukt ist ein Netz mit Farb-/Texturinformationen, das als 3D-Modell exportiert werden kann.




Abbildung 49: 3D-texturierte Umgebung, erstellt mittels Photogrammetrie

Simulation Datenerfassung und Sensor Einrichten

Als Kamerasensor verwendet das Valeo AVP Team die Valeo Fisheye-Kamera der zweiten Generation. Die Kameras mit ihren spezifischen intrinsischen und extrinsischen Eigenschaften können in CARLA Simulator oder Blender an der gewünschten Stelle in der Umgebung eingefügt werden.




Abbildung 50: Aufbau des Fisheye-Kamera-Sensors in der Valeo Kronach Teststrecke



Abbildung 51: Fischaugenkamera Nummer 5 Bildausgabe. (links) in Blender auf Photogrammetrie 3D Model (mitte) in dSpace Aurelion (rechts) der realen Kamera



Abbildung 52: Fischaugenkamera Nummer 0 Bildausgabe. (links) in Blender auf Photogrammetrie 3D Model (mitte) in dSpace Aurelion (rechts) der realen Kamera



Abbildung 53: Fischaugenkamera Nummer 0 Bildausgabe: (links) in Blender auf Laserscanner-Punktwolke (rechts) in CARLA Simulator

Stand der Arbeiten (31.12.2023)

Ein digitaler Zwilling ist eine Darstellung eines physischen Objekts, einer Person oder eines Prozesses, kontextualisiert in einer digitalen Version seiner Umgebung. Im letzten Bericht wurde erläutert, wie wir den digitalen Zwilling unserer Valeo-Testumgebung in Kronach erstellt haben. Dieses Mal wird erklärt, wie der digitale Zwilling unseres Valeo-Testfahrzeugs (VW Passat) erstellt und in den CARLA-Simulator importiert wurde.




Abbildung 54: Valeo-Testfahrzeug, importiert in die CARLA Unreal Engine

Binden und Modellieren des Fahrzeugs mit Blender

Um sicher zu sein, dass das Fahrzeug erfolgreich in CARLA verwendet werden kann, ist es notwendig, einen Prozess zu durchlaufen, der das korrekte Binden des Skeletts an die Basis und die Räder des Fahrzeugs, das Erstellen eines physischen Assets und das Exportieren in das fbx-Format beinhaltet.




Abbildung 55: Erstellen eines physischen Assets des Fahrzeugs in Blender

Importieren und Konfigurieren des Fahrzeugs in die Unreal Engine

Nachdem die fbx-Datei des Fahrzeugs erstellt und aus Blender exportiert wurde, kann sie in die Unreal Engine importiert und konfiguriert werden, indem man dem 10-Schritte-Tutorial folgt, wie es auf der offiziellen CARLA Simulator-Seite https://CARLA.readthedocs.io/en/latest/tuto_A_add_vehicle/ erklärt wird.






Abbildung 56: Erstellen eines physischen Assets und Blueprint des Fahrzeugs in Unreal Engine

Materialien und Texturen erstellen

Die Textur des Valeo-Testfahrzeugs wurde als tga-Datei erstellt, aus der das Material nach dem Import in die Unreal Engine erstellt werden kann. Nachdem das Material erstellt wurde, kann es im Fahrzeug-Mesh-Blueprint auf das Äußere des Fahrzeugs übertragen werden.




Abbildung 57: Erstellen von Materialien aus Texturen in der Unreal Engine

Stand der Arbeiten (31.3.2023)

Die Carla-Integration für den digitalen Zwilling von Valeo für den Anwendungsfall Autonomes Valet Parking wurde als Postersession auf der KI Wissen Abschlussveranstaltung präsentiert. Für dieses Arbeitspaket wurde die Erstellung einer benutzerdefinierten Umgebung in Autodesk Revit auf der

Grundlage der Blaupause aus einer hochdichten 3D-Laserscanner-Punktwolke (Reica 360) vorgestellt. Als zweiter Teil der Erstellung des digitalen Zwillings wurde vorgestellt, wie eine benutzerdefinierte Straße mit dem Tool Mathworks Roadrunner erstellt wurde, und schließlich wurde präsentiert, wie ein VW Passat als Valeo-Testfahrzeug erstellt und in den Carla Simulator importiert wurde.

3.1.3 TP3: Wissenskonformität

Tabelle 8: Struktur von TP3

TP/AP	Titel	Leitung
TP3	Wissenskonformität	Valeo
AP3.1	Physikalische Zusammenhänge	DLR
AP3.2	Welt- und Expertenwissen	Fraunhofer IAIS
AP3.3	Extrahierte Konzepte	FZI
AP3.4	Kombination von Methoden	FZI

3.1.3.1 AP3.1 Physikalische Zusammenhänge

Aufgaben von Valeo

- Plausibilisierung der Umgebungsbedingungserkennung aus AP1.2 durch gezielte Manipulation der Input-Daten

Stand der Arbeiten (30.6.2021)

Während des Berichtszeitraums wurden verschiedene Möglichkeiten gesammelt, die Entscheidungen des neuronalen Netzes durch Wissen plausibel zu machen und die Konformität mit dem Wissen sicherzustellen. Eine erste Anwendung der Plausibilisierung ist für den Prototyp des Netzes zur Erkennung von Alterungseffekten geplant.

Eine Möglichkeit zur Plausibilität von detektierten Alterungseffekten ist der Vergleich mit dem tatsächlichen Alter der Sensoren. Weiterhin ist es etabliertes Wissen, dass Alterungseffekte typischerweise langsam mit der Zeit entstehen und üblicherweise sich nicht von allein wieder umkehren. Eine Plausibilisierung der Klassifizierung des neuronalen Netzes wäre durch ein Speichern und nachgelagertes Auswertung der erkannten Alterungsklassen über einen langen Zeitraum denkbar.

Ein Test der Plausibilisierung kann über die Einspeisung von Messdaten aus verschiedenen Alterungsklassen (z. B. ohne Alterung bzw. nach starker Alterung) erfolgen. Allerdings ist zu berücksichtigen, dass beim Test andere Zeitskalen vorliegen als beim Echtzeitbetrieb. Dies müsste über eine entsprechende Skalierung berücksichtigt werden. Als Metrik für die Zuverlässigkeit kann das Netz neben der aktuell erkannten Alterung zusätzlich eine Konfidenz ausgeben.

Stand der Arbeiten (31.12.2021)

Die laufenden Forschungsarbeiten von Valeo zur Wissensintegration in AP1.1 und AP1.2 fokussieren sich auf Welt- und Expertenwissen. Im Gegensatz zu den Planungen der Vorhabensbeschreibung befasst sich Valeo nicht mit physikalischem Wissen in AP3.1 und dessen Plausibilisierung. Die

entsprechenden Arbeiten werden daher in schriftlicher Abstimmung mit der TP3-Leitung und dem Projektträger unter AP3.2 unter der Plausibilisierung von Welt- und Expertenwissen dargelegt.

3.1.3.2 AP3.2 Welt- und Expertenwissen

Aufgaben von Valeo

- Plausibilisierung der Objekterkennung aus AP1.1 durch gezielte Manipulation der Input-Daten
 - Erarbeitung einer Definition der zu manipulierenden Input-Daten
 - Ableitung von Plausibilisierungsmetriken
 - Erzeugung der manipulierten Input-Daten

Stand der Arbeiten (30.6.2021)

Zu Beginn der Arbeit in diesem Arbeitspaket wurden die Ideen für die Plausibilisierung der Objekterkennung aus AP1.1 mittels Weltwissen konkretisiert. Die Prädiktionen des Ausgangsmodells zur Objektdetektion sollen mittels eines Vergleichs mit vorhandenen ausgewählten geometrischen Modellen der Objekte auf Plausibilität überprüft werden. Hierbei steht die Vermeidung von falsch positiven Detektionen im Vordergrund. Auch ein Plausibilisierungsversuch mittels semantischer Segmentierung der Punktwolken scheint möglich. Beide Ideen sollen in Zukunft weiter ausgearbeitet werden.

Zusätzlich zu den genannten Arbeiten wurde an allen regelmäßigen Telefonkonferenz teilgenommen.

Stand der Arbeiten (31.12.2021)

Valeo erforscht in diesem Arbeitspaket die Detektion von Fehlern im optischen Pfad der hauseigenen LiDAR-Sensoren, welche aufgrund von Alterung auftreten können. Dabei ist eine Erkennung von falsch-positiven Detektionen wichtig, welche zu einem Ausfall der Fahrfunktion und damit zu einer unnötigen Unzufriedenheit des Kunden führen.

Das Wissen zur Plausibilisierung der Netzergebnisse wurde konkretisiert. Das Alter der Sensoren kann nicht zur Kontrolle der Klassifikation verwendet werden, da es der Software nicht zur Verfügung steht. Stattdessen wird der Umstand genutzt, dass es sich bei alterungsbedingten Störungen des optischen Pfads um irreversible Prozesse handelt. Die Falschausrichtung kann im Laufe der Zeit nur gleichbleiben oder zunehmen. Wird eine geringere Falschausrichtung nach eine stärkeren erkannt, ist dies unplausibel. Wird eine starke Fehlausrichtung nur hin und wieder in einigen Punktwolken während der Fahrt detektiert, kann auch dies als falsch positives Ergebnis verworfen werden. Hier wird das Wissen genutzt, dass der Alterungsprozess in langen Zeiträumen abläuft. Daher ist es möglich lange Sequenzen an Punktwolken auszuwerten, bevor die Erkennung Alarm schlägt.

Die Plausibilisierung der Detektion von Dejustierung ist während der Laufzeit im Fahrzeug möglich. Die Funktion kann durch Manipulation der Eingabedaten getestet werden. Beispielsweise werden Punktwolken verschiedener Alterungsklassen in gedrehter Reihenfolge eingespeist. Als weiterer Schritt soll ein Maß für die Plausibilität bestimmt werden, welches zusätzlich zur detektierten Klasse ausgegeben werden soll.

Des Weiteren plant Valeo eine Plausibilisierung der Ergebnisse der 3D-Objektdetektion. Hierbei sollen Modelle einzelner Objekte als a priori Wissen verwendet werden. Basierend auf einer geeigneten Metrik sollen die Prädiktionen bewertet werden. In Anlehnung an die Arbeiten in AP1.1 und AP1.4 wird Valeo sich zunächst auf Personenkraftwagen beschränken und zunächst eine Plausibilisierung mit Gaußschen Mischverteilungen und Wahrscheinlichkeitsdichtefunktion testen.

Stand der Arbeiten (30.6.2022)

Mit Beginn des hier relevanten Berichtszeitraums konzentriert sich Valeo in AP3.2 auf die Plausibilisierung von erkannten Fußgängern in Kameradaten. Ziel ist eine Reduktion der entsprechenden Falsch-Positiv-Rate. Im Rahmen der Projekte AVP und AFW wird mit statischen Kameras für die Objekterkennung gearbeitet. Diese Kameras sind an Wänden oder Decken montiert. Dadurch haben die Kameras einen festen Sichtbereich. Für jede Kamera nehmen wir ein Bild auf, welches nur die statische Umgebung enthält. Beweglichen Objekte, wie Personen oder Autos, sind nicht enthalten. Durch Vergleich des Bildausschnitts eines detektierten Objekts mit demselben Ausschnitt im statischen Bild können falsch-positive Detektionen identifiziert werden.




Abbildung 58: Vergleich einer detektierten Person (unten) mit demselben Ausschnitt im statischen Bild (oben). Das Bild mit der Person wurde zusätzlich photometrisch verfremdet (Helligkeit, Kontrast, Sättigung, Farbton). Spalten von links nach rechts: Farbbild, Farbbild normiert, graukonvertiert, graukonvertiert normiert.

Im ersten Schritt muss eine geeignete Vergleichsmethode gefunden werden. Es wurden verschiedene Methoden verglichen, wie zum Beispiel der Index struktureller Ähnlichkeit ("structural similarity index" auf Englisch mit der Abkürzung SSIM), die merkmalsbasierten Methoden der skaleninvarianten Merkmalstransformation ("scale-invariant feature transform" auf Englisch mit der Abkürzung SIFT) und "oriented FAST and Rotated BRIEF" (ORB).

Abbildung 58 zeigt ein Beispiel für solch einen Bildervergleich. Die untere Reihe zeigt eine erkannte Person (photometrisch verfremdet), die obere Reihe denselben Ausschnitt im statischen Bild. Die erste Spalte zeigt die Bilder in Farbe, so wie sie von der Kamera aufgenommen werden. In der zweiten Spalte wurden die Farbbilder mit dem jeweiligen Mittelwert und der Standardabweichung normiert. Die dritte Spalte enthält die graukonvertierten Bilder, die vierte die graukonvertierten, normierten Aufnahmen. Für diese vier Versionen wurde eine statistische Auswertung des SSIM erstellt, siehe Abbildung 59. Es wurden jeweils 1000 Bildpaare, von denen das zweite Bild zufällig variierte photometrische Parameter (Helligkeit, Kontrast, Sättigung, Farbton) aufweist, erstellt. Berechnet wurden Mittelwert, Standardabweichung, Minimum und

Maximum des SSIM. Trotz der photometrischen Störungen ist es möglich, einen Grenzwert zwischen den falsch-positiven und den richtig-positive Erkennungen im betrachteten Datensatz festzulegen.

Person - Person photometrisch gestört

Farbe: mittel: 0.93, Stdabw.: 0.06, Min.: 0.61, Max.: 1.00
Farbe normiert: mittel: 0.94, Stdabw.: 0.02, Min.: 0.87, Max.: 1.00
grau: mittel: 0.94, Stdabw.: 0.06, Min.: 0.63, Max.: 1.00
grau normiert: mittel: 0.96, Stdabw.: 0.02, Min.: 0.90, Max.: 1.00

leer - leer photometrisch gestört

Farbe: mittel: 0.95, Stdabw.: 0.05, Min.: 0.73, Max.: 1.00
Farbe normiert: mittel: 0.95, Stdabw.: 0.02, Min.: 0.89, Max.: 1.00
grau: mittel: 0.95, Stdabw.: 0.05, Min.: 0.74, Max.: 1.00
grau normiert: mittel: 0.95, Stdabw.: 0.03, Min.: 0.88, Max.: 1.00

Person - leer photometrisch gestört

Farbe: mittel: 0.53, Stdabw.: 0.02, Min.: 0.45, Max.: 0.56
Farbe normiert: mittel: 0.47, Stdabw.: 0.00, Min.: 0.46, Max.: 0.48
grau: mittel: 0.55, Stdabw.: 0.02, Min.: 0.46, Max.: 0.57
grau normiert: mittel: 0.47, Stdabw.: 0.01, Min.: 0.45, Max.: 0.48

leer - Person photometrisch gestört

Farbe: mittel: 0.53, Stdabw.: 0.05, Min.: 0.42, Max.: 0.63
Farbe normiert: mittel: 0.47, Stdabw.: 0.01, Min.: 0.46, Max.: 0.49
grau: mittel: 0.54, Stdabw.: 0.04, Min.: 0.43, Max.: 0.64
grau normiert: mittel: 0.47, Stdabw.: 0.01, Min.: 0.45, Max.: 0.49

Abbildung 59: Statistische Auswertung von jeweils 1000 Bildpaaren, von denen das zweite Bild zufällig variierte photometrische Parameter (Helligkeit, Kontrast, Sättigung, Farbton) aufweist. Berechnet wurden jeweils Mittelwert, Standardabweichung, Minimum und Maximum des SSIM. Es wurde sowohl die detektierte Person mit demselben Ausschnitt im statischen Bild verglichen, als auch die Person bzw. der leere Bereich mit sich selbst.

Es hat sich herausgestellt, dass der SSIM auch bei photometrisch gestörten Bildern (zufällige Variation von Helligkeit, Kontrast, Sättigung und Farbton) bessere Ergebnisse liefert als die merkmalsbasierten Methoden, die in dieser Hinsicht per Design toleranter sein müssten.

Stand der Arbeiten (31.12.2022)

Valeo hat sich innerhalb dieses Arbeitspakets zum Ziel gesetzt, die Detektion von Fußgängern in Kameradaten auf Plausibilität zu prüfen, um die Falsch-Positiv-Rate zu reduzieren. Die betrachteten Kameras sind fest montiert (z. B. an Wand oder Decke) und haben einen festen Sichtbereich. Dadurch ist es möglich, ein leeres Kamerabild, ohne zu detektierende Objekte, als "Wissen" zu benutzen.

Nachdem im letzten Berichtszeitraum ein Algorithmus entwickelt und statistisch getestet wurde, wurde er nun implementiert und in das KI Wissen-Projektarchiv hochgeladen.¹⁷ Die Integration in den Demonstrator steht noch aus. Eine Dokumentation auf Gitlab und Confluence wurde erstellt.

In den letzten Monaten wurden Realdaten für den Test des Netzes aufgenommen. Für Valeo ist es wichtig, das Netz nicht nur mit simulierten Daten zu testen. Bestehende Datensätze enthalten in der Regel kein leeres Bild, weshalb nicht darauf zurückgegriffen werden konnte und Aufnahmen speziell für diesen Anwendungsfall nötig wurden. Erste Tests mit den Daten und der

¹⁷ <https://gitlab.com/ki-wissen/tp3/ap3.2/valeo-plausibility-check-with-static-images>

Implementierung wurden durchgeführt. Durch Tests und Anpassungen ist eine weitere Verbesserung des Algorithmus zu erwarten. Diese Arbeiten können fortgeführt werden, sobald die Baseline von KI Wissen zur Verfügung gestellt wird.

Stand der Arbeiten (30.6.2023)

In den vorigen Berichtszeiträumen wurde ein Algorithmus entwickelt, um Detektionen von Fußgängern in Kameradaten auf Plausibilität zu prüfen und die Falsch-Positiv-Rate zu reduzieren. Im vorliegenden Anwendungsfall sind die Kameras fest montiert (z. B. an der Wand im Parkhaus) und erlauben so die Nutzung eines "leeren" Kamerabildes ohne zu detektierende Objekte als Wissen. Der Algorithmus wurde weiter getestet. Außerdem wurde ein Patent dafür beantragt. ("Verfahren zum Überprüfen eines neuronalen Netzwerks für eine Objektklassifizierung", 30. Januar 2023)

Stand der Arbeiten (31.12.2023)

In den vorangegangenen Berichtszeiträumen wurde ein Filter entwickelt, das die vom Netz ausgegebenen Detektionen auf Plausibilität überprüft. Damit soll die Falsch-Positiv-Rate reduziert werden. Der Algorithmus macht sich zunutze, dass die Kameras an Wand oder Decke fest montiert sind und es somit möglich ist, ein *leeres* Kamerabild ohne zu detektierende Objekte als Wissen zu nutzen.

Im aktuellen Berichtszeitraum wurde die Evaluierung des Filters implementiert und eine statistische Auswertung mit simulierten CARLA-Daten durchgeführt. Die Relevanz der Detektionen (das heißt die Wahrscheinlichkeit, dass ein detektiertes Objekt auch tatsächlich ein Objekt ist), konnte durch das Filter von 75 % auf 96 % gesteigert werden. Die Sensitivität des Filters (die Wahrscheinlichkeit, dass ein korrekt detektiertes Objekt auch vom Filter für ein Objekt gehalten wird) beträgt 99 %. Die Spezifität (also die Wahrscheinlichkeit, dass ein falsch erkanntes Objekt vom Filter abgefangen wird) liegt bei 88 %.

Stand der Arbeiten (31.3.2024)

Valeo arbeitet in diesem Arbeitspaket mit stationär montierten Kameras mit festem Sichtbereich. Ein "leeres" Bild, d. h. ohne zu erkennende Objekte, wird als Wissen verwendet, um die Detektionen auf Plausibilität zu testen und die Falsch-Positiv-Rate zu reduzieren. Es wurden weitere Tests mit den zur Verfügung gestellten Carla-Daten durchgeführt, die aber aufgrund der Kürze der Zeit zu keinen wesentlichen Verbesserungen der bereits berichteten Leistungskennzahlen führten. Die Ergebnisse des Arbeitspakets wurden auf der Abschlussveranstaltung des Projekts am 21. März in Frankfurt am Main als Poster präsentiert.

3.1.3.3 AP3.3 Extrahierte Konzepte

Aufgaben von Valeo

- Plausibilisierung der Objekt- und Umgebungsbedingungserkennung aus AP1.1 und AP1.2 mit Hilfe des in AP2.2 extrahierten Wissens
- Formalisierung des Output-Wissens

Stand der Arbeiten (30.6.2021)

In diesem Berichtszeitraum wurden gemäß den Arbeiten im AP2.2 Wissen über Probleme in der Detektion von Nahfeld-Lidar-Sensoren erarbeitet. Eine Plausibilisierung zur korrekten Kompensation von Überbelichtung ist erst für die kommenden Monate geplant. Zusätzlich zu den hauseigenen Arbeiten wurde an den regelmäßigen Telefonkonferenzen teilgenommen.

Stand der Arbeiten (31.12.2021)

AVP ist eine der vielen Anwendungen von Fahrassistenzsystemen, die derzeit bei der Valeo erforscht und entwickelt werden (siehe AP2.2). Der typische Anwendungsfall für AVP ist das autonome Bewegen eines Fahrzeugs in einer kontrollierten Umgebung, wie einem Parkplatz. Das Fahrzeug fährt autonom zwischen den Parkplätzen und der Sammelstelle. Das System stützt sich auf die Sensoren zur Perzeption und die Software des Egofahrzeugs, sowie auf die Infrastruktur zur Erkennung von Hindernissen und Planung der Trajektorien.

Das Wahrnehmungssystem kann in bestimmten Situationen versagen, was zu einer Gefährdung von Fußgängern und andere Verkehrsteilnehmer in unmittelbarer Nähe führen kann. Im AP3.3 wollen wir die automatisierte Fahrfunktion mit einer leistungsfähigen Simulationsumgebung unterstützen. Im ersten Schritt erstellen wir eine realistische HD-Karte mit klassifizierten, statischen Objekten und exportieren diese in ein austauschbares Format. Die HD-Karte dient als Wissensgrundlage und wird für die Simulation des aktuellen Systems verwendet. Auf die HD-Karten können Parametervariationen angewendet werden, z. B. eine Änderung der Beleuchtung oder der Bodentopologie. Dadurch können Erkenntnisse über die genaue Ursache eines Fehlerverhaltens gewonnen werden um die Robustheit gegenüber ähnlichen Fehlerursachen zu gewährleisten. Die genannte Routine kann im Umkehrschluss die Erkennungsleistung des Wahrnehmungssystems verbessern.

Die akkumulierte LiDAR-Punktwolke liefert eine dichte Darstellung der gesamten Umgebung, d.h. alle Objekte sind ohne Semantik miteinander verknüpft. Für eine nachgelagerte semantische Segmentierung nutzen wir CNNs wie SalsaNext¹⁸ und RangeNet++¹⁹. Alternativ dazu kann bei Bedarf auch eine manuelle Segmentierung vorgenommen werden. Die semantische Segmentierung ermöglicht die Isolation verschiedener Objekte als Segmente von Punkten in der akkumulierten Punktwolke. Die Segmente können als Grundlage für kundenspezifische 3D-Assets, beispielsweise Häuser und Verkehrsteilnehmer, verwendet werden. Diese Assets können einzeln in die Simulationsumgebung importiert werden. Wir planen eine Verwendung des Simulators CARLA²⁰, um die kundenspezifischen Assets zu importieren und eine kundenspezifische Welt zu simulieren.

CARLA bietet eine Vielzahl von Sensormodellen zur Erzeugung von Rohdaten basierend auf diversen Agenten, wie Fußgänger oder Autos. Durch Veränderung der Topologie und der Materialeigenschaften, z. B. der Kamerareflexion im Phong-Beleuchtungsmodell. Dadurch können

¹⁸ Cortinhal, Tiago, George Tzelepis, and Eren Erdal Aksoy. "SalsaNext: Fast, uncertainty-aware semantic segmentation of LiDAR point clouds." International Symposium on Visual Computing. Springer, Cham, 2020.

¹⁹ Milioto, Andres, et al. "Rangenet++: Fast and accurate lidar semantic segmentation." 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2019.

²⁰ <https://carla.org/>

wir systematisch Szenarien untersuchen, welche zu einem Versagen des KI Systems geführt haben, um die genaue Ursache für das Versagen zu identifizieren. Wir planen einen Test der Wissensextraktion mit Yolact, einem modernen neuronalen Netz zur Instanzsegmentierung in Echtzeit.

Stand der Arbeiten (30.6.2022)

Für unsere Anwendung für die Objekterkennung haben wir das neuronale Netz Yolact² mit den Standartgewichten (öffentliche Datei mit Namen „yolact_base_54_800000.pth“) verwendet. Yolact ist ein vollständig faltungsbasiertes Modell für die Segmentierung von Instanzen in Echtzeit. Aus diesem Modell wurde im folgenden Schritt Wissen extrahiert. Mit der Simulation können wir relevante Szenarien erzeugen, die zu einem Fehlverhalten des KI-Systems führen. Durch weitere Variationen in der Simulation generieren wir Wissen zur genauen Ursache für dieses Fehlverhalten.




Abbildung 60: Problematische Szenarien, bei denen Autos oder Fußgänger ungenau oder gar nicht erkannt werden. Die oberen Bilder zeigen eine Variation der Größe der Fußgänger. Die unteren Bilder zeigen eine Variation der Farbe der Fahrzeuge.

Es wurden zwei Arten von Szenarien untersucht, in denen das KI-System ungenaue oder falsche Ergebnisse liefert (siehe Abbildung 60). Das eine Szenario hängt mit der unterschiedlichen Körpergröße und -ausrichtung von Fußgängern zusammen. Kleine Personen und Personen, die horizontal auf dem Boden liegen, werden schlecht erkannt. Das zweite Szenario bezieht sich auf unterschiedliche Farben der Autos, was zu unterschiedlichen Erkennungsraten führt. Die Orientierung und Größe der Fußgänger sowie die Farbe des Fahrzeugs sind Wissen, das extrahiert wurde. Eine erste Formalisierung dieses Wissens erfolgte durch die Speicherung der numerischen Klassifikationsergebnisse.

Mit diesem Wissen kann eine Plausibilisierung basierend auf den erkannten Objekten und unserem extrahierten Wissen stattfinden. Die Erkennung einer kleinen Person ist in weiteren Verarbeitungsschritten als sehr unsicher zu betrachten und sollte beispielsweise erst durch redundante Detektion mit anderen Sensormodalitäten bestätigt werden.

Des Weiteren soll dieses Wissen für eine Verbesserung der KI-Objekterkennung genutzt werden. Beispielsweise kann die Architektur des KI-Systems geändert und zusätzliche Verarbeitungsschritte in die Pipeline aufgenommen werden. Dafür wird im kommenden Berichtszeitraum die Formalisierung des Wissens und dessen Einbindung in die KI-Methoden aus TP1 angegangen.

Stand der Arbeiten (31.12.2022)

Die Modellierungs- und Simulationstools *Blender* und *CARLA Simulator* stellen eine Vielzahl von Kamerasensoren zur Verfügung, mit denen Daten aus dem virtuellen Umgebungsmodell gewonnen werden können. Durch Sensorsimulation in der virtuellen Umgebung können wir gezielt Szenarien untersuchen, die möglicherweise zu einem Ausfall des KI-Systems führen. Ein sensibler Parameter für das KI-System ist die Farbe des zu detektierten Fahrzeugs:



Abbildung 61: Szene Frontansicht - Auto mit blauer Farbe - Erkennung 93 %, Auto mit grüner Farbe - Erkennung Konfidenz 79 %

Number	Detection_Confidence	Red_Value	Green_Value	Blue_Value
1	0.76	0	0	0
2	0.78	0	0	85
3	0.92	0	0	128
4	0.93	0	0	255
5	0.53	0	85	0
6	0.78	0	85	85
7	0.84	0	128	0
8	0.79	0	128	128
9	0.88	0	128	255
10	0.79	0	255	0
11	0.84	0	255	255
12	0.84	85	85	85
13	0.82	85	85	128
14	0.89	85	85	255
15	0.81	85	128	85
16	0.66	85	128	128
17	0.91	128	85	85
18	0.91	128	85	128
19	0.60	128	128	128
20	0.91	128	128	255
21	0.84	255	0	0
22	0.91	255	0	255
23	0.88	255	85	0
24	0.89	255	85	85
25	0.93	255	85	255
26	0.60	255	128	0
27	0.89	255	128	128
28	0.91	255	128	255
29	0.68	255	255	0
30	0.87	255	255	255




Abbildung 62: Szene Frontansicht - Detektionskonfidenzen für erkannte Fahrzeugobjekte unterschiedlicher Farbe für die Fisheye-Kamera.



Abbildung 63: Szene Heckansicht - Auto mit blauer Farbe - Erkennung 90 %, Auto mit grüner Farbe - Erkennung Konfidenz 47 %.

Number	Detection_Confidence	Red_Value	Green_Value	Blue_Value
10.82		0	0	0
20.48		0	0	85
30.72		0	0	128
40.90		0	0	255
50.52		0	85	0
60.56		0	85	85
70.44		0	128	0
80.80		0	128	128
90.92		0	128	255
100.47		0	255	0
110.95		0	255	255
120.39		85	85	85
130.49		85	85	128
140.93		85	85	255
150.39		85	128	85
160.74		85	128	128
170.47		128	85	85
180.49		128	85	128
190.75		128	128	128
200.92		128	128	255
210.37		255	0	0
220.83		255	0	255
230.31		255	85	0
240.44		255	85	85
250.83		255	85	255
260.32		255	128	0
270.52		255	128	128
280.89		255	128	255
290.33		255	255	0
300.94		255	255	255




Abbildung 64: Szene Heckansicht - Detektionskonfidenzen für erkannte Fahrzeugobjekte unterschiedlicher Farbe für die Fisheye-Kamera.

Ein Fahrzeug wird in der virtuellen Testumgebung in fixen Posen von einer virtuellen Fischaugenkamera gesehen, und die Kameradaten werden von einem neuronalen Netzwerk hinsichtlich der Objekterkennung ausgewertet. Abhängig von der eingestellten Farbe wird das Fahrzeug mit unterschiedlicher Detektionsgüte (Konfidenz) erkannt. Zur Erkennung wird das Yolact verwendet, ein vollständig gefaltetes Modell für die Segmentierung von Instanzen in Echtzeit. Wir haben 30 verschiedene RGB-Werte für die Farbvariation von Autos verwendet und sie an zwei Konfigurationen (Position, Ausrichtung) für die Fischaugenkamera getestet, die auf gegenüberliegenden Seiten der Simulationsumgebung montiert waren. Die Abhängigkeit der Detektionsgüte von der Fahrzeugfarbe ist extrahiertes Wissen über das neuronale Netz. Die Tabellen der RGB-Farbwerte und der zugehörigen Detektionskonfidenzen ist in den obigen Abbildungen zusammen mit einem Balkendiagramm dargestellt. Aus den Balkendiagrammen lässt sich eine systematisch hohe Detektionsgüte für blaue und pinke Fahrzeuge erkennen. Fahrzeuge in den Farben gelb, orange und grün werden demgegenüber vergleichsweise schlecht erkannt. Quantitativ gefasst lässt sich zusammenfassen: In allen Testfällen, in denen Blau mit Maximalwert (255) eingestellt ist, beträgt die Konfidenz mindestens 83%. Für Kombinationen mit hohen Werten von Rot und Grün (--> gelbe, orange), beträgt die Erkennungskonfidenz in den betrachteten Fällen weniger als 68%. Dieses Wissen kann genutzt werden, um parametrische (farbliche) Schwächen des DNN zu identifizieren und das Training zu optimieren.

Stand der Arbeiten (30.6.2023)

Im vorliegenden Berichtszeitraum hat Valeo die Untersuchung der parametrischen Farbabhängigkeit der Detektionsgüte eines Fahrzeuges ausgeweitet. Dabei wurden Fahrzeuge in der virtuellen Testumgebung in fixen Posen von virtuellen Fischaugenkamera aufgenommen und die Kameradaten werden von einem neuronalen Netzwerk hinsichtlich der Objekterkennung ausgewertet. Abhängig von der eingestellten Farbe wird das Fahrzeug mit unterschiedlicher Detektionsgüte (Konfidenz) erkannt.

Zur Objektdetektion wird Yolact verwendet, ein vollständig gefaltetes Modell für die Segmentierung von Instanzen in Echtzeit. Wir haben die RGB-Werte Liste für die Variation der Autofarben auf 96 RGB-Werte erweitert. Die Detektionsgüte des Yolact Modells wurden an zwei Fischaugenkamerakonfigurationen (Position, Ausrichtung), die auf gegenüberliegenden Seiten der Simulationsumgebung montiert waren, getestet. Die Abhängigkeit der Detektionsgüte von der Fahrzeugfarbe ist extrahiertes Wissen über das neuronale Netz.




Abbildung 65: Szene Frontansicht: Lila-farbenes Auto - Erkennungskonfidenz 81%, Rotes Auto - Erkennungskonfidenz 90%




Abbildung 66: Balkendiagramm mit 96 RGB-Wertevariationen für Fischaugenkamera Nummer 0

Tabelle 9: Detektionskonfidenzen für erkannte Fahrzeugobjekte unterschiedlicher Farbe. Variationen zwischen roten und blauen RGB-Werte für die Fisheye-Kamera 0.

Detection_Confidence	Red_Value	Green_Value	Blue_Value
0.86	16	0	0
0.86	16	0	16
0.84	16	0	32
0.89	16	0	64
0.77	16	0	128
0.90	16	0	255
0.83	32	0	0
0.85	32	0	16
0.79	32	0	32
0.92	32	0	64
0.89	32	0	128
0.83	32	0	255
0.84	64	0	0
0.93	64	0	16
0.92	64	0	32
0.93	64	0	64
0.91	64	0	128
0.52	64	0	255
0.95	128	0	0
0.95	128	0	16
0.92	128	0	32
0.88	128	0	64
0.94	128	0	128
0.43	128	0	255
0.90	255	0	0
0.89	255	0	16
0.94	255	0	32
0.94	255	0	64
0.92	255	0	128
0.81	255	0	255

Aus den Balkendiagrammen lässt sich für die Fischaugenkamera "0" eine systematisch hohe Detektionsgüte für rote und orangene Fahrzeuge erkennen. Fahrzeuge in grünen Farben werden demgegenüber vergleichsweise schlecht erkannt. In allen Testfällen, in denen Blau und Rot mit Minimalwert (16) eingestellt ist, beträgt die Konfidenz mindestens 77%.




Abbildung 67: Szene Frontansicht: Schwarzes Auto - Erkennungsgüte 94%, Grünes Auto - Erkennungsgüte 46%.




Abbildung 68: Balkendiagramm mit 96 RGB-Wertevariationen für Fischaugenkamera Nummer 5.

Tabelle 10: Detektionskonfidenzen für erkannte Fahrzeugobjekte unterschiedlicher Farbe für die Fisheye-Kamera 5

Detection_Confidence	Red_Value	Green_Value	Blue_Value
0.94	0	0	0
0.81	0	0	16
0.87	0	16	0
0.88	0	0	32
0.90	0	32	0
0.87	16	0	0
0.92	32	0	0
0.54	0	255	0
0.46	0	255	16
0.54	0	255	32
0.33	0	255	64
0.55	0	255	128
0.40	0	255	255
0.58	16	255	0
0.44	32	255	0
0.57	64	255	0
0.42	128	255	0
0.29	255	255	0

Fahrzeuge in Grüntönen werden auch von der Fischaugenkamera “5” schlecht erkannt.

In allen Testfällen, in denen Grün mit Maximalwert (255) eingestellt ist, beträgt die Konfidenz maximal 58%. Fahrzeuge in dunklen Farben werden von der Fischaugenkamera “5” gut erkannt. In allen Testfällen, in denen nur eine Farbe Rot, Grün oder Blau mit Maximalwert (32) eingestellt ist, beträgt die Konfidenz mindestens 81%.

Das extrahierte Wissen aus diesen Ergebnissen kann genutzt werden, um parametrische (farbliche) Schwächen des DNN noch erweitern zu identifizieren und das Training zu optimieren.

Stand der Arbeiten (31.12.2023)

In diesem Berichtszeitraum hat Valeo die Untersuchung der parametrischen Farbabhängigkeit der Erkennungsqualität auf ein speziell angefertigtes Fahrzeug ausgeweitet.



Abbildung 69: VW Passat importiert in CARLA Unreal Engine mit verschiedenen Texturen (braun-grün, orange, blau, rot)

Die Textur des benutzerdefinierten Fahrzeugs, das in den CARLA-Simulator importiert wurde, kann geändert werden, indem das Material, das aus der in den Unreal Editor Content importierten tga-Texturdatei erstellt wurde, auf ein Materialteil gelegt wird, dass das Außenmaterial des Fahrzeugs darstellt. Um eine Farbe aus der Texturdatei in eine andere zu ändern, wurde das GIMP-Tool verwendet.




Abbildung 70: Ändern der Farben der tga-Texturdatei: von der Standardfarbe grün-braun zu rot.

Fahrzeuge wurden in der virtuellen Testumgebung in festen Posen von virtuellen Fischaugenkameras aufgenommen und die Kameradaten werden von einem neuronalen Netz hinsichtlich der Objekterkennung ausgewertet. Abhängig von der eingestellten Farbe wird das Fahrzeug mit unterschiedlicher Erkennungsqualität (Konfidenz) erkannt.



Abbildung 71: Auto mit grüner Farbe - Erkennung 80 %, Auto mit blauer Farbe - Erkennung Konfidenz 92 %.




Abbildung 72: Liste der erkannten Autoobjekte und zugehöriges Balkendiagramm mit RGB-Werten für die Fisheye-Kamera 0 für 96 RGB-Wert-Variationen.



Abbildung 73: Auto mit schwarzer Farbe - Erkennung 93 %, Auto mit grüner Farbe - Erkennung Konfidenz 57 %.




Abbildung 74: Liste der erkannten Autoobjekte und zugehöriges Balkendiagramm mit RGB-Werten für die Fisheye-Kamera 5 für 96 RGB-Wert-Variationen.

Zur Objektdetektion wird Yolact verwendet, ein vollständig gefaltetes Modell für die Segmentierung von Instanzen in Echtzeit. Wir haben die RGB-Werte Liste für die Variation der Autofarben auf 96 RGB-Werte erweitert. Die Detektionsgüte des Yolact Modells wurden an zwei Fischaugenkamerakonfigurationen (Position, Ausrichtung), die auf gegenüberliegenden Seiten der Simulationsumgebung montiert waren, getestet. Anstelle eines Fahrzeugs aus der CARLA-Standardfahrzeugbibliothek haben wir ein speziell angefertigtes Fahrzeug VW Passat verwendet. Die Abhängigkeit der Detektionsgüte von der Fahrzeugfarbe ist extrahiertes Wissen über das neuronale Netz.

Fahrzeuge in Grüntönen werden auch von beide Fischaugenkameras “0” und “5” schlecht erkannt. In allen Testfällen, in denen Grün mit Maximalwert (255) eingestellt ist, beträgt die Konfidenz maximal 85%. Das extrahierte Wissen aus diesen Ergebnissen kann genutzt werden, um parametrische (farbliche) Schwächen des DNN noch erweitern zu identifizieren und das Training zu optimieren.

Stand der Arbeiten (31.3.2023)

In der KI Wissen Final Event Poster Session wurden verschiedene Autofarben als Szenario präsentiert, in dem das KI-System Ergebnisse mit unterschiedlicher Erkennungssicherheit liefert. Das Bild einer Fischaugenkamera, die auf der gegenüberliegenden Seite der Testumgebung angebracht ist, wurde als Referenz verwendet. Die Liste der 96 verschiedenen RGB-Werte für Autofarben mit der entsprechenden Objekterkennungswahrscheinlichkeit, die von Yolact ausgegeben wurde, wurde als BAR-Diagramm dargestellt. Bei diesem Beispiel der Fisheye-Kamera wurde deutlich, dass Autos mit einem höheren Grünwert mit einer geringeren Erkennungswahrscheinlichkeit als 80% erkannt wurden.

3.1.3.4 AP3.4 Kombination von Methoden

Aufgaben von Valeo

- Plausibilisierung der Situationserkennung aus AP2.2 durch Kombination der Methoden aus AP3.1-AP3.3
 - Plausibilisierung über Weltwissen (Methode aus AP3.2)

Stand der Arbeiten (30.6.2021)

Der Beginn der Arbeiten für AP3.4 ist laut Vorhabenbeschreibung erst für den 1. Oktober 2021 angesetzt und damit nicht im Berichtszeitraum.

Stand der Arbeiten (31.12.2021)

Das AP3.4 hatte am 29. November 2021 den Kick-off. Valeo legte dabei die Pläne zur Plausibilisierung der Perzeption von LiDAR und Kamera aus AP1.1 und AP1.2 dar. Diese Arbeiten hängen stark an den aufkommenden Ergebnissen der genannten APs. Erste Konzepte von Valeo in AP3.4 beschäftigen sich mit der Plausibilisierung der LiDAR-Perzeption durch einen Test mit simulierten Daten unter Einfluss von Dejustierungen der Optik.

Stand der Arbeiten (30.6.2022)

Das AP3.4 hatte am 29. November 2021 seinen Kick-off. Valeo konnte im vorliegenden Berichtszeitraum bereits erste Konzepte zu der Kombination von Methoden erarbeiten. Im AP1.2 nutzen wir statische Bilder zur Verbesserung der Objekterkennung auf Fischaugenkameras. In AP2.2 wird Wissen über die Objekterkennung des DNNs Yolact extrahiert, welches in unserem Fall ebenfalls auf Fischaugenkameras arbeitet. Das extrahierte Wissen über problematische Szenarien kann dann zur Plausibilisierung der Objekterkennung genutzt werden, was in AP3.3 beschrieben wird.

Für die Methodenkombination wollen wir im ersten Schritt Wissen über die statische Umgebung der Fischaugenperzeption generieren. Beispielsweise testen wir den Einfluss der Umgebungsbeleuchtung oder der Textur des Untergrundes auf die Klassifikationsergebnisse. Dieses Wissen lässt eine Plausibilisierung der gesamten Erkennung einer Kamera zu. Im äußersten Fall wird in der Selbstdiagnostik der Kamera erkannt, dass das Gerät unter diesen Bedingungen nicht arbeiten kann und beispielsweise weitere Lichtquellen in der Umgebung benötigt.

Stand der Arbeiten (31.12.2022)

Valeo konnte im vorliegenden Berichtszeitraum weiter an den Konzepten zu der Kombination von Methoden arbeiten. Im AP1.2 nutzen wir statische Bilder zur Verbesserung der Objekterkennung auf Fischaugenkameras. In AP2.2 wird Wissen über die Objekterkennung des DNNs Yolact extrahiert, welches in unserem Fall ebenfalls auf Fischaugenkameras arbeitet. Das extrahierte Wissen über problematische Szenarien kann dann zur Plausibilisierung der Objekterkennung genutzt werden (s. AP3.3).

Für die Methodenkombination wollen wir im ersten Schritt Wissen über die statische Umgebung der Fischaugenperzeption generieren. Beispielsweise testen wir den Einfluss der

Umgebungsbeleuchtung oder der Textur des Untergrundes auf die Klassifikationsergebnisse. Dieses Wissen lässt eine Plausibilisierung der gesamten Erkennung einer Kamera zu. Im äußersten Fall wird in der Selbstdiagnostik der Kamera erkannt, dass das Gerät unter diesen Bedingungen nicht arbeiten kann und beispielsweise weitere Lichtquellen in der Umgebung benötigt werden.

In einem nächsten Schritt können die jeweiligen Konformitätsprüfungen auf ein bestimmtes DNN zugeschnitten werden, indem das aus diesem DNN extrahierte Wissen verwendet wird. Die Wissensextraktion könnte zum Beispiel ergeben, dass das DNN anfällig für falsche Erkennungen von Objekten mit einer bestimmten Farbe oder Form ist. Die entsprechende Konformitätsprüfung könnte dann auf einen niedrigeren Auslöseschwellenwert eingestellt werden, um falsche Erkennungen in diesen Fällen häufiger zu erkennen.

Darüber hinaus können Kamera- und Lidar-Detektionen auf Objektebene fusioniert werden. Die Übereinstimmung der beiden Module in Bezug auf das jeweilige Klassifikationsergebnis kann als Konformitätsprüfung für das Kamera- und das Lidarmodul dienen. Die Objektfusion ermöglicht eine Verschmelzung der vorgenannten Konformitätsprüfungen, d.h. der Prüfung auf Basis statischer Kamerabilder und der Prüfung auf Basis von Objektmodellen (s. AP1.4). Wird eine der beiden Konformitätsprüfungen ausgelöst, kann es zu Fehldetektionen kommen.

Stand der Arbeiten (30.6.2023)

Im vorliegenden Berichtszeitraum konnte Valeo signifikante Fortschritte in AP1.2 "A priori Wissen-basierte Architekturen" berichten. Die Verwendung eines statischen Bildes als *a priori* Wissen zeigt durchgehend Verbesserungen der Sensitivität und der mittleren Relevanz. Durch Verwendung der *Background Aware Individual Resnet* (BAIR) Architektur konnten weitere Verbesserungen gezeigt werden.

Parallel dazu wurde in AP3.3 für statische Umgebungen die parametrische Abhängigkeit der Detektionsgüte von der Fahrzeugfarbe aufgezeigt.

Die Demonstratorintegration in TP4 ermöglicht eine Kombination dieser Methoden, indem das Netzwerk aus AP1.2 in der Testumgebung aus AP3.3 zur Objektdetektion verwendet wird. Aktuell ist das Netzwerk auf Realdaten, die im Rahmen eines Kundenprojekts ("Automated Valet Parking", AVP) in einem Parkhaus aufgenommen wurden trainiert. Für die Demonstratorintegration würde ein umfangreicher Katalog an Trainingsdaten aus der virtuellen CARLA Testumgebung benötigt werden. Die Möglichkeit, diesen Datensatz bereit zu stellen, wird aktuell geprüft.

Stand der Arbeiten (31.12.2023)

Im vorliegenden Berichtszeitraum gab es von Valeo Seite keine weiteren Beiträge.

Stand der Arbeiten (31.3.2023)

Valeo hat Konzepte zur Kombination der Methoden aus AP1.2 und AP3.3 erstellt und damit die Arbeiten in AP3.4 abgeschlossen. Aus diesem Grund hat sich Valeo in diesem Berichtszeitraum auf organisatorische Aufgaben beschränkt.

3.1.4 TP4: Enabler, Integration und Demonstration

Tabelle 11: Struktur von TP4

TP/AP	Titel	Leitung
TP4	Enabler, Integration und Demonstration	AVL
AP4.1	Use Cases, Gütekriterien und Metriken	Capgemini Engineering
AP4.2	Gesamtsystemkonzept	AVL
AP4.3	Implementierung und Integration AD-Stack	AVL
AP4.3	Erzeugung und Bereitstellung Datensätze	Valeo
AP4.5	Evaluation und Demonstration	FZI

3.1.4.1 AP4.1 Use Cases, Gütekriterien und Metriken

Aufgaben von Valeo

- Beitrag zur Use Case Definition und Metrikkatalog
 - Detailliertere Spezifikation der Use Cases 1 bis 3 zur geeigneten Demonstration der geplanten Vorhaben in TP1-3
 - Definition von geeigneten Metriken zur Evaluation der geplanten Vorhaben aus TP1-3 für die Use Cases 1-3.

Stand der Arbeiten (30.6.2021)

Die im AP1.1 geplante 3D-Objektdetektion ist als grundlegende Perzeption für die drei Use Cases in KI Wissen relevant. Eine Verbesserung und Plausibilisierung dieser Perzeption durch Anwendung von a priori Wissen lässt sich anhand aller drei Use Cases verifizieren. Hierbei können Standard-Metriken aus der 3D-Objekterkennung verwendet werden, wie die Mean Average Precision (engl. für mittlere Relevanz), Mean Average Recall (engl. für gemittelte Durchschnitts-Sensitivität) oder Area Under Curve (engl. für Fläche unter der Kurve).

Im AP 1.2 beschäftigt sich Valeo mit der Detektion von Alterungseffekten bei Lidar-Sensoren. Aufgrund dessen kann entschieden werden, ob der Sensor verlässliche Informationen liefert. Dies ist für eine zuverlässige Erkennung von Fußgängern (Use Case 1) und einen sicheren Spurwechsel (Use Case 2) von Bedeutung. Die Zuverlässigkeit der Sensordaten soll über eine Konfidenz ausgegeben werden. Als Metrik zur Beurteilung des Algorithmus kann die Korrelation zwischen den Metriken für die Objekterkennung (siehe obigen Abschnitt) und deren Konfidenzen dienen.

Stand der Arbeiten (31.12.2021)

Valeo hat sich in im Berichtszeitraum an der Erstellung von Use Cases für KI Wissen beteiligt. Der Fokus lag auf der Fußgängererkennung in Use Cases 1. Insbesondere engagierte sich Valeo bei der Ausarbeitung des Use Cases 1.5, welcher sich mit autonomem Parken mit mehreren Parkplätzen beschäftigt.

Als Umgebung für den Anwendungsfall AVP (siehe AP2.2) kommt ein intelligentes Parkhaus in Frage. Der Kunde übergibt sein Fahrzeug an einem definierten Übergabepunkt an den Dienstleister und holt es dort nach einer entsprechenden Anfrage wieder ab. In der Zwischenzeit parkt das Fahrzeug selbständig, was in Abbildung 75 anhand einer Simulation von Valeo gezeigt wird. Als Simulationsplattform dient das Automotive Simulation Model von dSpace. Die Szene bildet die Teststrecke am Valeo Standort in Kronach nach.



Abbildung 75: Simulierter Einparkvorgang im Automated-Valet-Parking für Use Case 1.5.

Im AVP Typ 1 wird die Sensorik des automatisierten Fahrzeugs für den Einparkvorgang genutzt. Dies setzt einen hohen Automatisierungs- und Vernetzungsgrad der Fahrzeuge voraus. Valeo fokussiert sich in den gezeigten Arbeiten jedoch auf den AVP Typ 2, bei dem die Sensorik der Parkinfrastruktur genutzt wird. Hier können fest montierte Kameras und LiDAR-Sensoren zum Einsatz kommen. Aufgrund dieser Anwendung wurde der Use Case 1.5 um die Definition dieser statischen Sensoren erweitert.

Stand der Arbeiten (30.6.2022)

Im Berichtszeitraum hat sich Valeo bei der Erstellung des neuen Use Cases 1.6 eingebracht und diesen auf Confluence unter <https://confluence.vdali.de/x/mYpOBw> abgelegt. Abbildung 76 zeigt den Use Case 1.6 schematisch mit sechs statischen Kameras in der Infrastruktur eines Parkplatzes und ein bewegtes Fahrzeug. Im Wesentlichen wird der Einparkvorgang in der Kundenfunktion AVP behandelt.




Abbildung 76: Use Case 1.6 zum autonomen Einparken mit statischen Sensoren.

Die Fußgängererkennung auf den statischen Kameras bilden ein Kernelement von zukünftigen AVP Funktionen, da Fußgänger durch vollautomatisierte Fahrzeuge grundsätzlich einer erhöhten Gefährdung ausgesetzt sind. Erschwerend kommt hinzu, dass die Erkennung von Fußgängern technologisch sehr anspruchsvoll ist. Personenkraftwagen sind in erster Linie starre Körper, welche im Parkhaus durch eine Position am Boden und eine Orientierung im Gierwinkel hinreichend gut charakterisiert sind. Personen hingegen können beispielsweise stehen, sitzen oder rennen, was nicht durch Modelle des starren Körpers beschrieben werden kann. In diesem Sinne beschäftigt sich Valeo im AVP-Projekt stark mit der Erkennung von Fußgängern in TP1 und der entsprechenden Extraktion von Wissen in TP2.

Stand der Arbeiten (31.12.2022)

Auf dem Project Meeting in Karlsruhe am 5./6. Oktober 2022 wurde eine Diskussionsrunde zu den Metriken der Fußgängererkennung durchgeführt. Die von den Partnern entwickelten Methoden sollen nicht nur mit funktionalen Metriken bewertet werden (z. B. Sensitivität und Relevanz für die Objekterkennung), sondern möglichst auch mit Metriken auf Systemebene. Darunter versteht man Metriken, die die Verbesserung einer simulierten Testfahrt bewerten. Es wird also nicht bewertet, wie sehr sich die Objekterkennung (Funktion) verbessert, sondern wie die geänderte Objekterkennung das autonome Fahrzeug (System) verbessert. Ein Beispiel dafür ist die Kollisionserkennung, für die die Anzahl der Zusammenstöße mit anderen Verkehrsteilnehmern während der Simulation ausgewertet wird.

Für die Teilprojekte 1 und 3 lassen sich ähnliche Metriken festlegen, wie zum Beispiel Kollisionserkennung, Abstand zwischen Verkehrsteilnehmern, Szenariendauer bis Zusammenstoß. Schwieriger ist es, ein Systemmaß für die Methoden des Teilprojekts 2 (Wissensextraktion) zu

finden. Die Anwendungen dieser Methoden finden sich eher in der Fehleranalyse von neuronalen Netzen, die sich schwer mit einer simulierten Fahrt bewerten läßt.

Stand der Arbeiten (30.6.2023)

Zur Charakterisierung der in TP3 entwickelten Methoden und Domänen zur Konformitätsprüfung wurde eine Bewertungsmatrix erarbeitet, welche die Ansätze unter anderem hinsichtlich ihrer Skalier- und Erweiterbarkeit bewertet. Die individuellen Ansätze der TP3-Partner zur Validierung der Übereinstimmung des Wissens variieren stark hinsichtlich ihres konzeptionellen Ansatzes sowie ihres Umfangs in Bezug auf die Anwendungsfallsszenarien. Dadurch ist ein sinnvoller direkter Vergleich anhand quantitativer Kennzahlen nicht möglich. Daher erfolgt die Bewertung der Ansätze auf Basis einer methodischen Taxonomie, die wesentliche Merkmale qualitativ erfasst. Die Bewertungsmatrix ist im folgenden dargestellt:

Tabelle 12: Taxonomiematrix zur Charakterisierung von KI-basierten Konformitätsprüfungen.

Category	Description	Attributes UC1- Ped. Detection	Attributes UC2 - Lane Change	Attributes UC3 - Rule Break
Online/ Offline	Can the method be applied online or only offline?	online / self-consistent possibly with delay offline /depended may require additional data (database, internet, ...) and/or postprocessing	online / self-consistent possibly with delay offline /depended may require additional data (database, internet, ...) and/or postprocessing	online / self-consistent possibly with delay offline /depended may require additional data (database, internet, ...) and/or postprocessing
Interpretability	Does the method provide an (intuitive) interpretation of its conformity assessment? - i.e. information directly linking the outcome to the input.	Visual (e.g. heat map) Numerical /Scale (e.g. energy, time, violation of constraints) Abstract decision (e.g. binary outcome yes/no)	Visual (e.g. heat map) Numerical /Scale (e.g. energy, time, violation of constraints) Abstract decision (e.g. binary outcome yes/no)	Visual (e.g. heat map) Numerical /Scale (e.g. energy, time, violation of constraints) Abstract decision (e.g. binary outcome yes/no)

Scalability (Quantity)	Scaling to higher number of objects/features is realized <i>intrinsically/vertically</i> (e.g. number of detected peds in DNN object detection) or scaling requires the deployment of additional instances: <i>extrinsic/horizontal</i> scaling. (e.g. tracking individual objects).	Intrinsic /vertical scaling Extrinsic /horizontal scaling	Intrinsic /vertical scaling (<i>how many other traffic participants can be incorporated into the trajectory planning</i>) Extrinsic /horizontal scaling	Intrinsic /vertical scaling (<i>how many other traffic participants can be incorporated into the rule break</i>) Extrinsic /horizontal scaling
Extensibility / Adaptability (Quality)	Can the method be extended to additional features such as other object classes?	• Yes intrinsic (<i>within the PED class to pedestrians in different poses e.g. lying, crooked, etc. and/or to children/skaters/etc.)</i>) • Yes extrinsic (<i>new classes such as cars, trucks, ...</i>) • No	• Yes (<i>Extensibility to additional lanes</i>) • Yes (<i>Extensibility to to more traffic rules</i>) • Yes (<i>other type of extensibility</i>) • No	• Yes (<i>Extensibility to to more traffic rules</i>) • Yes (<i>other type of extensibility</i>) • No
Robustness	Robustness could be inherited from the quality of the extracted knowledge. Robustness is not a binary measure but is always a robustness against variations in specific parameters (e.g. location, pose, color, ...)	Provide empirical or anecdotal evidence. (FPs, Change of ODD)	Provide empirical or anecdotal evidence. (FPs, Change of ODD)	Provide empirical or anecdotal evidence. (FPs, Change of ODD)
Performance	This "performance" metric should capture the reliability of the conformity check by answering whether the outcome of the conformity check is justified, i.e. corresponds to the factual situation. (This discriminates the conformity check metric from the more accuracy based metrics in TP1.)	Provide empirical or anecdotal evidence.	Provide empirical or anecdotal evidence.	Provide empirical or anecdotal evidence.

Die Arbeiten des Arbeitspakets AP4.1 zu “Use Cases, Gütekriterien und Metriken” im KI-Wissen Projekt sind damit abgeschlossen.

Stand der Arbeiten (31.12.2023)

Die Arbeiten des Arbeitspakets AP4.1 zu “Use Cases, Gütekriterien und Metriken” im KI-Wissen Projekt wurden bereits mit der Erstellung der Taxonomiematrix zur Charakterisierung der in TP3 entwickelten Methoden abgeschlossen. Darüber wurde im vorausgehenden Zwischenbericht No.5 berichtet (Stand der Arbeiten (30.6.2023)).

3.1.4.2 AP4.2 Gesamtsystemkonzept

Aufgaben von Valeo

- Definition des Gesamtsystems
- Mitarbeit bei der Definition des Gesamtsystems mit Fokus auf:
 - Spezifikation der Sensoren
 - Spezifikation der Metadaten
- Spezifikation der Datenformate

Stand der Arbeiten (30.6.2021)

Im Rahmen des Arbeitspakets fanden regelmäßig Meetings statt, in denen mit der Definition des Gesamtsystems begonnen wurde. Es wurde vor allem der im Projekt zu verwendende AD-Stack diskutiert. AVL hat hierzu mögliche Lösungen vorgestellt, welche von Valeo kommentiert wurden. Hierbei hat Valeo insbesondere Erfahrungen zu der Simulationsumgebung Carla eingebracht.

Im Rahmen vom AP1.1 und AP1.2 fokussiert sich Valeo auf die Interpretation von Punktwolken der hauseigenen Lidar-Sensoren. Die Datensätze zum Training der Netzwerke werden in der Simulation und in realen Messfahrten erzeugt. Der Realitätsgrad der Trainingsdatensätze spiegelt sich am Ende auch in der Leistungsfähigkeit der neuronalen Netze im realen Betrieb wieder. Daher bilden Daten aus realen Messfahrten weiterhin den Grundpfeiler für die Funktionsentwicklung. Innerhalb von Valeo erfolgt die Gewinnung von Realdaten in diversen Projekten mit zugehörigen Spezifikationen an Datenformate. Daher wurde bei Valeo im ersten Schritt eine Verarbeitungskette zur Konvertierung von Datensätzen aus diversen Projekten entwickelt. Punktwolken werden als Ethernet-Stream im PCAP-Format (Abk. für Packet CAPture) gespeichert. Dieses Format wird universell für das Mitschneiden von Netzwerkverkehr genutzt. Diverse Open Source Bibliotheken sind hierfür verfügbar, wie die libpcap-Bibliothek auf Unix-Systemen oder die WinPcap-Bibliothek auf Windows-Systemen.

Im nächsten Verarbeitungsschritt werden die Punktwolken in ein PCD-Format (Abk. für Point Cloud Data) konvertiert. Durch die Speicherung der Punktwolken in Binärdateien und die geringe Menge an Zusatzdaten wie dem Datei-Header sind PCD-Dateien effizient in Sachen Speicherplatz. Das PCD-Format ist ebenfalls auf diversen Systeme und Programmiersprachen über die PCL-Bibliothek (Point Cloud Library) einlesbar und damit als universelles Eingangsdatenformat für die KI-Entwicklung geeignet.

Im Berichtszeitraum wurden die Werkzeuge zur Konvertierung entwickelt und diese auf ersten Datensätzen aus einem Valeo-Serienprojekt getestet.

Stand der Arbeiten (31.12.2021)

Die Spezifikation der Datenformate, insbesondere der Sensor- und Metadatenformate wurde von Valeo im Berichtszeitraum unterstützt. Um den Austausch von Daten über die KI Familie hinweg

zu erleichtern, wurden die Spezifikationen der Datenformate des Projektes KI Datatooling untersucht und im Rahmen eines AP-Treffens von KI Wissen vorgestellt. Dabei wurde festgestellt, dass die vorhandenen Datenformate auch den Anforderungen von KI Wissen genügen.

Valeo bringt ein bestehendes Testfahrzeug zur Aufnahme von Realdaten mit diversen Sensoren in das Projekt ein. Eine detaillierte Beschreibung des Fahrzeugs ist dem Bericht unter AP 4.4 zu entnehmen.

Stand der Arbeiten (30.6.2022)

Grundlage für das Labelingformat in KI Wissen bildet das Labelingformat aus dem Projekt KI Data Tooling. Dieses wird entsprechend den Anforderungen der Projektpartner adaptiert und aktuell überarbeitet. Insgesamt werden 20.000 einzelne Bilder aus Kamera- und Lidardaten annotiert. Bei Lidar-Punktewolken werden 3D Bounding Boxes für erkannte Objekte erstellt. Bei Kamerabilder sind es 2D-Rechtecke oder Quader. Objektklassen für das Labeling sind Pkw, Bus, Fahrrad mit dem Fahrer, Einsatzfahrzeuge, Fußgänger, Verkehrszeichen, Lichtsignale und Baustellenmarkierungen. Über eine Präzisierung und Ergänzung der Klassen muss in AP4.4 diskutiert werden. Beispielsweise können erkannte Fußgänger als Kinder und Erwachsene klassifiziert werden. Auch eine Einordnung von Fahrzeugen in SUV, Kombi, Transporter ist denkbar. Des Weiteren muss über zusätzliche Informationen ebenfalls entschieden werden. Möglich sind hier Attribute ganzer Szenen, wie etwa Straßenzustand, Wetter und Lichtverhältnisse.

Zusätzlich zu der Annotation der Daten muss eine Anonymisierung erfolgen. Die Datenschutz-Grundverordnung (DSGVO) erfordert dazu ein Unkenntlichmachen von Gesichtern und Nummernschildern. Unter Leitung von Valeo wird im GUA3 eine Firma beauftragt, die sowohl das Labeling als auch die Anonymisierung durchführt.

Stand der Arbeiten (31.12.2022)

Im vorliegenden Berichtszeitraum hat Valeo die Leistungsbeschreibung für den GUA3 in Form der Labeling-Spezifikation erarbeitet und mit dem Konsortium abgestimmt. Die Leistungsbeschreibung konkretisiert die Kategorien "*Labeling allgemein*", "*Anonymisierung*", "*3D Bounding Boxes*", "*2D-Cuboids*", "*2D semantische Instanzsegmentierung*" und "*Flexible Annotation*". Die Ergebnisse sind auf [Confluence](https://confluence.vdali.de/display/KIWissen/GUA3+Leistungsbeschreibung) tabellarisch aufgeführt:
<https://confluence.vdali.de/display/KIWissen/GUA3+Leistungsbeschreibung>

- In der Kategorie "Labeling allgemein" sind wichtige Aspekte des Datenschutzes sowie grundsätzliche Rahmenbedingungen für das Datenlabeling definiert.
- Im Punkt "Anonymisierung" wird erläutert, welches technische Vorgehen notwendig ist, um DSGVO konforme Daten zu generieren.
- In der Kategorie "3D Bounding Boxes" sind die Attribute geschildert, die Informationen über die Boundingbox der aufgenommenen Punktewolken von Laserscans liefern. Es muss jedem Objekt das Attribut *Klasse* zugeordnet werden. Dieses kann beispielsweise eine Person oder ein Fahrzeug sein. Die Klassen wiederum werden in der Leistungsbeschreibung genau definiert. So wird der Person zum Beispiel die Unterklasse Fußgänger oder Radfahrer zugeordnet.

- Für die Kategorie “2D Cuboids” gelten die gleichen Klassen wie bei “3D Bounding Boxes”. Die Daten, die hier zugrunde liegen, sind allerdings keine LaserScans, sondern Kamerabilder. Technische Details zur Erzeugung der Bilder werden in diesem Kapitel beschrieben und Anforderungen an die Genauigkeit der Annotation gestellt.
- In der Kategorie “2D semantische Instanzsegmentierung” werden im Wesentlichen weitere benötigte Klassen erklärt und ebenfalls Genauigkeitsanforderungen festgehalten.
- Zuletzt wird in der Kategorie “flexible Annotation” dokumentiert, dass gegebenenfalls zusätzliche Annotationsanforderungen im Rahmen des Projekts auftreten können. Diese können weitere gelabelte Daten der zuvor beschriebenen Kategorien oder neue Annotationsaufgaben sein.

Um gesetzliche Vorgaben einzuhalten, muss eine öffentliche Ausschreibung für den GUA3 erstellt werden, da im Konsortium die Entscheidung getroffen wurde, dass die Forschungsausnahme nach §116 GWB für das Projekt nicht gültig ist.

Valeo hat einen ersten Entwurf der öffentlichen Ausschreibung erstellt und an die Anwälte des Fraunhofer Institut geschickt, die den Prozess der öffentlichen Ausschreibung betreuen sollen.

Stand der Arbeiten (30.6.2023)

Im vorliegenden Berichtszeitraum hat Valeo die Arbeiten zur Labeling-Spezifikation bzw. der Leistungsbeschreibung für den GUA3 fortgeführt. Hintergrund ist die Entscheidung für eine öffentliche Ausschreibung seitens des Konsortiums. In Zusammenarbeit mit den Projektpartnern (insbesondere DLR) wurden Anforderungen gemäß der Form einer öffentlichen Ausschreibung definiert. Diese Anforderungen wurden in Meetings abgestimmt. Es wurde ein Rating eingeführt, um die Wichtigkeit der einzelnen Anforderungen zu bestimmen. Dies erfolgt durch eine Punktevergabe. Punkte werden dabei für Anforderungen vergeben, die nicht zwingend erfüllt sein müssen. In der Kategorie “Labeling allgemein” gibt es ausschließlich solche Mindestanforderungen und daher keine Extrapunkte. In den Kategorien “Anforderung an das Labeling”, “Anforderungen an die Anonymisierung”, “Anforderungen an die Auslieferung” und “Anforderungen an die Kosten” können Zusatzpunkte erzielt werden. Der Anbieter mit den meisten Punkten soll den Zuschlag erhalten.

Die Kategorie “Labeling allgemein” umfasst weiterhin wichtige Datenschutzaspekte und grundlegende Rahmenbedingungen für das Datenlabeling. Hier wird erklärt, wie man sicherstellt, dass die generierten Daten den Anforderungen der Datenschutzgrundverordnung (DSGVO) entsprechen. Ergänzt wurde zudem der Punkt “Karteninformation”.

Unter dem Punkt “Anforderungen an die Anonymisierung” wird beschrieben, welche technischen Verfahren erforderlich sind, um die Daten so zu verändern, dass sie nicht mehr auf einzelne Personen zurückverfolgt werden können.

In der Kategorie “Anforderungen an das Labeling” werden die Eigenschaften definiert, die Informationen über die Begrenzungsboxen der erfassten Punktwolken aus Laserscans liefern. Jedes Objekt muss einer bestimmten Klasse zugeordnet werden. Die genauen Definitionen dieser Klassen werden in den Spezifikationen festgelegt.

Die Kategorie “flexible Annotation” wurde in Absprache mit den Projektpartnern aus den Anforderungen entfernt.

Stand der Arbeiten (31.12.2023)

Im vorliegenden Berichtszeitraum hat Valeo Arbeiten für den GUA3 fortgeführt. Die öffentliche Ausschreibung hat CapGemini Outsourcing gewonnen und ist damit jetzt für die Annotierungen im GUA3 verantwortlich. In Zusammenarbeit mit CapGemini hat Valeo die bestehenden Anforderungen an die Annotierung in mehreren Meetings abgestimmt und detailliert. Hervorzuheben ist dabei die Überarbeitung eines Spezifikationsdokuments speziell für das Annotationsformat. Die Spezifikation wurde entsprechend den Anforderungen in KI-Wissen angepasst und enthält allgemeine Vorgaben sowie Erläuterungen zu Koordinatensystemen, Netzwerkeingaben, Bounding Boxen, semantischer Segmentierung und Posenannotationen.

Zweiter Schwerpunkt der Arbeiten seitens Valeo war die Auswahl von Realdaten, die annotiert werden sollen. Mit dem Erprobungsfahrzeug wurden zuvor Daten u.a. entsprechend der Use Cases in KI Wissen aufgezeichnet. Diese wurden so prozessiert, dass sie dem abgestimmten Format in KI Wissen entsprechen. Dies umfasst beispielsweise die Vereinheitlichung der Framerate aller Sensoren auf 10fps. Als nächstes erfolgte die Auswahl geeigneter Sequenzen bzw. Clips. Dazu wurden alle Daten aufbereitet, geprüft und nach ihrer Eignung bewertet. Die Eignung zeichnet sich insbesondere durch das Erfüllen eines Use Cases sowie durch ausreichend viele Fußgänger im Use Case 1 und ausreichend viele Fahrzeuge im Use Case 2 aus. Geeignete Sequenzen wurden dabei in dem Datensatz für folgende Use Cases gefunden: 1.1, 1.2, 1.3, 1.5, 2.2, 2.3, 2.4, 2.5. Die Datenauswahl und Prozessierung erfolgte in Abstimmung mit AVL. AVL und Valeo stellen insgesamt etwa 120 Sequenzen mit einer durchschnittlichen Länge von einer Minute bereit.

Stand der Arbeiten (31.3.2024)

Zusätzlich zum EVB-IT Vertrag bestand wegen des abgeschlossenen Joint Controller Agreements (JCA) zwischen den Konsortialpartnern die Notwendigkeit einer Geheimhaltungsvereinbarung (GHV) und eines Data Processing Agreements (DPA) aller Konsortialpartner mit dem Unterauftragnehmer. Die Erstellung und Unterzeichnung dieser Vertragsdokumente erstreckte sich bis Februar 2024.

Nach vollständiger Unterzeichnung aller Vertragsdokumente konnte Valeo die im Rahmen von AP4.4 eingefahrenen Daten Capgemini Outsourcing zur Verfügung stellen. Diese wurden zuvor entsprechend den Anforderungen des Projekts (insbesondere Anforderungen an die Use Cases aus TP4) selektiert und vorverarbeitet (siehe vorheriger Stand der Arbeiten (31.12.2023)).

Im Verlauf des Projekts kam es zu nicht unerheblichen Verzögerungen des GUA 3. Ein Grund dafür war die entschiedene Notwendigkeit einer öffentlichen Ausschreibung und der organisatorische sowie rechtliche Mehraufwand, der damit einherging. Ein weiterer Grund waren benötigte Vertragsdokumente mit dem Unterauftragnehmer. Wie bereits dargestellt, wurden erst im Januar 2024 alle Vertragsdokumente vom gesamten Konsortium final akzeptiert und bis Februar 2024 unterschrieben.

Aufgrund der Verzögerungen konnten die Daten nicht innerhalb der Projektlaufzeit für die Validierung von Algorithmen auf den Versuchsträgern genutzt werden. Das Konsortium hat sich

dazu entschieden, den GUA3 trotzdem abzuschließen und den Datensatz für Folgeprojekte zur Verfügung zu stellen. Der Abschluss des GUA3 konnte allerdings nicht bis zum Projektende erfolgen, sodass Arbeiten darüber hinaus notwendig werden. Dies betrifft insbesondere die Qualitätssicherung von Annotationen des Datensatzes. Die Überprüfung der Korrektheit und Vollständigkeit und damit die Abnahme des GUA3 soll in den Monaten nach Projektende erfolgen.

Für diesen Zweck hat Valeo zusammen mit Capgemini Outsourcing und dem Konsortium folgenden Zeitplan vereinbart. Die annotierten Daten sollen in drei Batches geliefert werden. Diese sollen nach und nach die geforderten Leistungen (Annotationen) enthalten. Die erste Teillieferung ist bereits erfolgt. Die zweite Teillieferung soll Ende Juni erfolgen. Dann soll Valeo ebenfalls das Annotierungstool von Capgemini Outsourcing bereitgestellt werden. Mithilfe dieses Tools sollen nach der zweiten und dritten Teillieferung jeweils eine Qualitätskontrolle und eine Feedbackrunde über mögliche Änderungen an den Unterauftragnehmer durchgeführt werden. Die dritte Teillieferung soll Ende Juli erfolgen. Mit Abschluss der Qualitätskontrolle der dritten Teillieferung und der Überarbeitung möglicher Fehler wird der GUA3 dann abgeschlossen sein.

3.1.4.3 AP4.3 Implementierung und Integration AD-Stack

Aufgaben von Valeo

- Mitarbeit am AD-Stack
 - Mitarbeit bei der Definition des Gesamtsystems mit Fokus auf:
 - Zusammenarbeit mit anderen Partnern zum Aufsetzen des AD-Stack
 - Zusammenarbeit mit anderen Partnern zum Aufsetzen und Erweitern der Simulationsumgebung CARLA

Stand der Arbeiten (30.6.2021)

Der Beginn der Arbeiten für AP4.3 ist laut Vorhabenbeschreibung erst für den 1. September 2021 angesetzt und damit nicht im Berichtszeitraum.

Stand der Arbeiten (31.12.2021)

Valeo hat im Berichtszeitraum das ROS-Interface des Demonstrators von AVL getestet. Dieses Interface basiert auf der ROS-Version “Noetic”, welche unter Linux Ubuntu 20 betrieben wurde. Nach diversen Anpassungen und einer Abstimmung mit AVL wurde das gewünschte Ergebnis erzielt.

Stand der Arbeiten (30.6.2022)

Die Hauptaufgabe von Valeo in AP4.3 besteht darin, den Code des KI-Wissen-Partners AVL für die Simulationengenerierung mit dem CARLA-Simulator²¹ zu testen. Vor dem Ausführen einer Simulation muss ein Docker-Image erstellt werden, welches alle erforderlichen Eingabedaten enthält. Das

²¹ Alexey Dosovitskiy et al. “CARLA: An Open Urban Driving Simulator”. In: Proceedings of the 1st Annual Conference on Robot Learning. 2017, pp. 1-16.

Projekt basiert auf dem Linux-Betriebssystem Ubuntu. Der standardmäßige Build-Befehl erstellt ein Beispiel-Runner-Image zum Ausführen eines Szenarios.




Abbildung 77: Ego-Fahrzeug folgt der Fahrspur in der Standard-Stadt von CARLA und auf einer benutzerdefinierten Straße.

Zwei verschiedene Umgebungsszenarien wurden von Valeo getestet. Ein Szenario, in dem ein Ego-Fahrzeug, in diesem Fall ein rot gefärbtes Tesla Model 3 der Fahrspur mit konstanter Geschwindigkeit in der Standard Stadt von CARLA folgt. Im zweiten Szenario folgt ein Ego-Fahrzeug mit konstanter Geschwindigkeit der Fahrspur auf einer benutzerdefinierten Straße.

Stand der Arbeiten (31.12.2022)

Die Hauptaufgabe der Valeo-Beteiligung an diesem Projekt besteht darin, den geschriebenen Code des KI-Wissen-Partners AVL für die Simulationsgenerierung des Ego-Fahrzeugs mit dem CARLA Simulator zu testen. Das Projekt basiert auf dem Linux-System Ubuntu und ROS als Framework. Der standardmäßige Build-Befehl erstellt ein Runner-Image, das die Umgebung und das Szenario ausführt. Beim zweiten offenen Projekttag-Workshop, der am 18.01.2023 in Schloss Birlinghoven in Sankt Augustin stattfand, wurden drei neue Szenarien und Ego-Fahrzeug Fahrerassistenzfunktionen vorgestellt und getestet: LKA-Lane Keeping Assistance, ACC-Adaptive Cruise Control, LCA-Lane Change Assistance. Es wurden zwei Simulationsumgebungen vorgestellt: Die erste ist eine speziell angefertigte Demostraße mit sechs Fahrspuren, die zweite in der CARLA Standardstadt Nummer 04.




Abbildung 78: Ego-Fahrzeug mit Spurhaltassistent in Demoumgebung und in der CARLA-Stadt 04.



Abbildung 79: Ego-Fahrzeug überholt Pkw.



Abbildung 80: Ego-Fahrzeug bremsst aufgrund von Annäherung an den Fußgänger.

Es wurden zwei Szenarien vorgestellt: Ein Szenario zeigt die Spurhaltassistent durch ein Ego-Fahrzeug, das ein anderes Fahrzeug überholt. Das Ego-Fahrzeug bremsst bei Annäherung an das andere Fahrzeug ab, wechselt auf die linke Spur und beschleunigt wieder. Das zweite Szenario zeigt eine Notbremsung, wenn sich das Ego-Fahrzeug einem Fußgänger nähert, der den Zebrastreifen überquert. Das Ego-Fahrzeug bremsst ab, hält an, wartet bis der Fußgänger die Straße überquert hat, und fährt weiter.

Stand der Arbeiten (30.6.2023)

Zum Zweck der Demonstratorintegration muss eine dem Anwendungsfall entsprechende Szenario-Datei und gegebenenfalls eine Map- und OpenDrive-Datei erstellt werden.




Abbildung 81: Valeo Anwendungsfall Use Case 1.6

Für Valeo ist der Anwendungsfall 1.6 relevant, bei dem die Erkennung von verdeckten, stehenden/bewegten Fußgängern auf dem Parkplatz durch stationäre Kameras erreicht wurde. Für die Erstellung der Open Drive-Datei haben wir Roadrunner verwendet, das auch die Möglichkeit bietet, die erstellte Straße zusammen mit der Umgebung zu exportieren, die zuvor in Autodesk Revit erstellt wurde.




Abbildung 82: Valeo Teststrecke Erstellung in Roadrunner und Visualisierung der geöffneten Laufwerksdatei in OpenDrive Viewer.

Für die Erstellung des Szenarios wurde ein Python Skript verwendet, um Wegpunkte aus OpenDrive zu generieren. Die Wegpunkte wurden aus den Fahrspuren generiert und das Auto wurde an der gewünschten Stelle in der Fahrspur gepawnt, woraufhin sein Antrieb den generierten Wegpunkten folgend navigiert, bis er das definierte Ziel auf der Fahrspur erreicht (das Ziel wurde mit dem ausgewählten Zielpunkt definiert).




Abbildung 83: Szenario - Fahrzeug folgt den Wegpunkten, Fußgänger geht auf festgelegter Route.



Abbildung 84: Fischaugenkamera Bildausgaben für laufendes Szenario.

Stand der Arbeiten (31.12.2023)

Um unser CARLA-System in den Demonstrator zu importieren, wurde am 31.08.2023 eine Videokonferenz mit Thomas Knorr von der Firma AVL anberaunt, in der Thomas uns die Schritte

zeigte, wie wir die maßgeschneiderte Umgebung und das Szenario in den Demonstrator importieren können. Als erster Schritt muss unsere Kronach Location Map in die Datei <map_package>.tar.gz importiert werden, um sie für den Demonstrator zu verwenden. Das Problem ist beim Erstellen des Demonstrators aufgetreten, nachdem das import_additional_assets Flag auf true gesetzt wurde. Die Texturen wurden, wie von Thomas Knorr (AVL) vorgeschlagen, aus der Map entfernt, aber das Problem besteht immer noch und die Integration in den Demonstrator war nicht erfolgreich.

```
client-carla-1 | ALSA lib conf.c:5007:(snd_config_expand) Evaluate error: No such file or directory
client-carla-1 | ALSA lib pcm.c:2495:(snd_pcm_open_noupdate) Unknown PCM default
client-carla-1 | Signal 11 caught.
client-carla-1 | Malloc Size=65538 LargeMemoryPoolOffset=65554
client-carla-1 | Malloc Size=131160 LargeMemoryPoolOffset=196744
client-carla-1 | Malloc Size=131160 LargeMemoryPoolOffset=327928
client-carla-1 | CommonUnixCrashHandler: Signal=11
client-carla-1 | Engine crash handling finished; re-raising signal 11 for the default handler. Good bye.
client-carla-1 | Segmentation fault (core dumped)
```

Nach der Teilnahme am TP3-Workshop, der am 27. und 28.11.2023 stattfand, und dem Erfahrungsaustausch mit anderen Partnern über die Integration des Demonstrators haben wir beschlossen, den Demonstrator nicht als Plattform für die Präsentation unserer Ergebnisse zu nutzen.

Stand der Arbeiten (31.3.2023)

Die Carla-Integration für den digitalen Zwilling von Valeo für den Anwendungsfall „Autonomes Valet Parking“ und das extrahierte Wissen basierend auf der Yolact-Objekterkennung wurden als Poster Session auf der KI Wissen Abschlussveranstaltung am 21. und 22.03.2024 in Frankfurt präsentiert. Bei der Carla-Integration wurde gezeigt, wie eine kundenspezifische Umgebung, ein kundenspezifisches Fahrzeug und kundenspezifische Fischaugenkamera-Sensoren erstellt und im Carla-Simulator implementiert wurden.

3.1.4.4 AP4.4 Erzeugung und Bereitstellung von Datensätzen

Aufgaben von Valeo

- Aufnahme und Bereitstellung von Realdaten
 - Aufbau und Vorbereitung eines Aufnahmefahrzeugs
 - Einbau der zur Datenaufnahme benötigten Sensorik wie Lidar oder Kamera
 - Extrinsische und intrinsische Kalibrierung der Sensoren zur Sicherstellung der räumlichen Datenkonformität
 - Zeitliche Synchronisierung der Sensoren für die Aufnahme zur Sicherstellung der temporalen Datenkonformität
 - Zusammenarbeit mit anderen Partnern zum Aufsetzen und Erweitern der Simulationsumgebung CARLA

- Einhaltung der geltenden Datenschutzverordnungen (z. B. Anonymisierung von Personen)

Stand der Arbeiten (30.6.2021)

Der Beginn der Arbeiten für AP4.4 ist laut Vorhabenbeschreibung für den 1. Juli 2021 angesetzt und damit nicht im Berichtszeitraum.

Stand der Arbeiten (31.12.2021)

Valeo hat für interne Forschung und im Rahmen anderer Förderprojekte ein Testfahrzeug aufgebaut (siehe Abbildung 85), welches mit Sensoren der verschiedenen Sensorklassen Kamera, LiDAR, Radar, Ultraschall und einer inertialen Messeinheit ausgestattet ist (siehe Abbildung 86). Für KI Datentooling ist schon eine Toolchain entwickelt worden, um die Daten für das Projekt aufzubereiten, zu synchronisieren und die Valeo LiDAR Daten zu fusionieren. Ebenso ist dort ein Datenformat definiert worden, dem der Partner AVL in KI Datentooling bereits zugestimmt hat. Mit der Projektleitung von KI Wissen und dem AP 4.4 ist die Wiederverwendung des vorhandenen Toolings abgestimmt.

Dieses Vorgehen gewährleistet eine effiziente Bearbeitung der Projekthalte, da auf funktionierende Hard- und Software zurückgegriffen werden kann. Zusätzlich ermöglicht es einen vereinfachten Austausch von wertvollen Realdaten zwischen den genannten Projekten.



Abbildung 85: Bild des Testfahrzeugs von Valeo mit diversen Kamera-, LiDAR-, Radar-, Ultraschall-Sensoren und einer inertialen Messeinheit.

Sensor type	Model	Resolution	Frame rate	Position	Output	Miscellaneous
Camera	FLIR Blackfly S GigE	1920 x 1200	25 Hz	front on the vehicle's roof, towards front	RGB images (not compressed)	
Camera	Valeo Long Range Camera	1280 x 800	30 Hz	roofrack, front middle, front left, rear left, rear middle, rear right, front right	JPEG	
Lidar	Velodyne HDL-64E	64 Layer, 360° HFoV, 26.9° VFoV	10 Hz	middle of the roof	Point cloud + intensity per point	
Lidar	Valeo Mobility Kit Scala	16 Layer, 360° HFoV, 10° VFoV	25 Hz	bumper height, front middle, front left, rear left, rear middle, rear right, front right	Point cloud + intensity per point	
Radar	Valeo Radar	4 sensors as 360° HFoV cocoon	20 Hz	at the corners of the vehicle at bumper height	Point cloud	
IMU	iNAT-FSSG-1	Position accuracy GNSS aided 0.02 m (rms) [RTK available] Heading accuracy: < 0.1 deg (GNSS aided)	Depends on the importance of the message: We use 50Hz and 250Hz	INS in trunk, GPS and cellular antennas on the roof, Wheel tick sensor on the rear-right wheel.	decoded CAN messages in defined JSON format	

Abbildung 86: Spezifikation der Sensoren im Valeo Aufnahmefahrzeug.

Die Sensoren werden entweder mit dem paketbasierten Synchronisationsstandard PTP (Abk. für „Precision Time Protocol“) synchronisiert oder sie sind direkt mit einer GPS-Antenne (Abk. für „Global Positioning System“) verbunden. Der PTP-Master ist ebenfalls an eine GPS-Antenne angebunden. Somit wird gewährleistet, dass alle Sensoren eine gemeinsame Zeitbasis haben und die Abweichung der Uhren der Sensoren zur Masterclock möglichst geringgehalten wird, d. h. im Idealfall unter 1 μ s.

Das komplette Fahrzeug befindet sich in einem kalibrierten und synchronisierten Zustand. Die Qualität der Kalibration wird fortlaufend überprüft und gegebenenfalls aktualisiert. Die Synchronisation anhand der GPS-Zeitstempel wird zu einem Mastersensor durchgeführt, in dem von allen Sensoren immer die nächstgelegenen Frames ausgewählt werden. Die Auswahl der Frames ist im Datenformat von KI Datentooling spezifiziert.

Die Daten werden als Einzelframes in gängigen Formate abgelegt oder in der Cloud-Plattform von DXC abgelegt. Die entsprechende Ordnerstruktur ist auf Abbildung 87 gezeigt.

Folder structure

- ki-w
 - input
 - <owner>
 - <date>_<time>_<recid>_<seqid>
 - annotations
 - <annotation_task>
 - sensor
 - <sensor_position>
 - <identifier>_<unix_timestamp_in_microseconds>.<sensor_file_ext>
 - camera_front
 - camera_front_left
 - calibs
 - <sensor_position>.json
 - ...
 - can.json
 - context.json

Abbildung 87: Ordnerstruktur für den Austausch von Messdaten.

Als Datenformate wurde PNG und JPG für Kameras ausgewählt. Punktwolken von Radar- und LiDAR-Sensoren werden als PCD abgespeichert. CAN-Nachrichten, Kalibrationsdaten und weitere optionale Kontextinformation werden in dem Textformat JSON ausgetauscht.

Die Einzelframes haben das folgende Benennungsschema:

- <identifier>_<unix_timestamp_in_microseconds>.<sensor_file_ext>

Der Identifier ist eine Nummer, welche die synchronisierten Frames einander zuordnet. Der Unix-Zeitstempel wird als UTC-Zeit in Mikrosekunden ausgegeben beginnend am ersten Januar 1970. Abschließend wird der Dateiname durch die zugehörige Dateiendung komplettiert.

Die Ordner einer Sequenz werden wie folgt bezeichnet:

- <date>_<time>_<recid>_<seqid>

Das Datum wird menschenlesbar dargestellt: z.B. 20200922 für den 20. September 2020. Die Uhrzeit wird nach dem gleichen Schema wie das Datum in Lokalzeit angegeben. Die Recorder-ID zeigt an, welche Entitäten an der Aufnahme der Sequenz beteiligt waren. Z.B. 000v000 für Valeo oder 0000a00 für AVL. Abschließend gibt es noch die Sequenz-ID, d. h. eine fünfstellige Zahl, die eindeutig einer Sequenz zugeordnet werden kann.

Im Zuge des AP 4.4 Meetings ist projektweit der Datenbedarf für die Use Cases abgefragt worden. Dabei war es von Interesse, ob synthetische Daten oder Realdaten verwendet werden und ob diese in nicht-anonymer Form verwendet werden müssen.

Zusätzlich hat das AP 4.4 die von AP 4.1 spezifizierten Use Cases auf die Umsetzbarkeit im Hinblick auf Realdaten und synthetische Daten untersucht. Valeo hat hierzu Lokalisationen für die praktische Umsetzung erörtert, sowie eine Einschätzung abgegeben, ob ein Szenario geplant oder gestellt

werden kann und wie häufig es auftritt. Weitere Szenarien mussten ausgeschlossen werden, da diese für das Aufnahmefahrzeug oder andere Verkehrsteilnehmer zu gefährlich wären.

Stand der Arbeiten (30.6.2022)

Valeo hatte im Berichtszeitraum die Leitung von AP4.4 inne. Im Kern wurden folgende Themen vorangetrieben:

1. Aufbau der Versuchsfahrzeuge bei AVL und Valeo
2. Planung der Formate zur Speicherung der Sensordaten
3. Planung der ersten Aufzeichnungsfahrten
4. Planung einer Erzeugung von synthetische Daten unter Beteiligung von AVL, DLR und fortiss

Im Speziellen hat Valeo im April 2022 eine erste Testfahrt zur Datenaufzeichnung unternommen. Nach Fertigstellung der DSGVO-Vereinbarung können diese Daten auch im Projekt geteilt werden.

Stand der Arbeiten (31.12.2022)

Valeo hatte im Berichtszeitraum die Leitung von AP4.4 inne. Im Kern wurden folgende Themen vorangetrieben:

1. Aufbau der Versuchsfahrzeuge bei AVL und Valeo.
2. Planung der Formate zur Speicherung der Sensordaten.
3. Planung der ersten Aufzeichnungsfahrten.
4. Planung einer Erzeugung von synthetischen Daten unter Beteiligung von AVL, DLR und fortiss.

Valeo hat eine Aufnahmefahrt in die Stadt Bayreuth und Umgebung unternommen, um gezielt die Szenarien 1.1, 1.2, 1.3, 1.4, 1.5 zum Use Case 1 - Fußgängererkennung bei Verdeckung sowie die Szenarien 2.2, 2.4 für den Use Case 2 - komplexer Spurwechsel einzufahren.

Zusätzlich sind zahlreiche vorhandene Aufnahmen aus vorangegangenen Aufnahmefahrten prozessiert und zum Teil auf ihre Eignung für die verschiedenen Szenarien untersucht worden.

Aufnahmetag	29.11.2021	30.11.2021	01.12.2021	02.12.2022	20.01.2022	09.12.2022
Stadt	Leonberg	Leonberg	Stuttgart	Reutlingen	Erlangen, Garching	Bayreuth
Anzahl der Sequenzen	22	14	55	28	93	7
Umgebung	hauptsächli ch urban	hauptsächli ch urban	hauptsächli ch urban und Wohngebiet e	urban, ländlich, Autobahn	5 Sequenzen ländlich, 70 Sequenzen Autobahn,	ländlich, urban

					18 Sequenzen urban	
--	--	--	--	--	--------------------------	--

Die Prozessierung der Daten beinhaltet die Konvertierung des Aufnahmeformates in das Projektformat. Hierbei werden mit sensorspezifischen Dekodierern aus den von den Sensoren übermittelten Netzwerkpaketen Bilder oder Punktwolken berechnet. Hierbei fließen die zeitliche Synchronisation und die räumliche Kalibration der Sensoren ein, um eine Fusion der unterschiedlichen Sensoren anhand der Daten zu ermöglichen. Hierfür werden die Kalibration und die Synchronisation validiert. Die oben aufgeführten Sequenzen sind im aktuellen Berichtszeitraum prozessiert worden. Die Sichtung der Daten hat bereits begonnen und wird kontinuierlich fortgesetzt. Die Zuordnung der Daten zu den Use Cases und der Upload stehen noch aus. Für die vorliegenden Daten wird dies im nächsten Berichtszeitraum abgeschlossen.



Abbildung 88: Bild aus einer Sequenz für den Use Case 2: "komplexer Spurwechsel".

Das Teilen der Sequenzen mit den Projektpartnern über eine Cloud Plattform steht noch aus, da noch nicht alle Partner die bürokratischen Formalitäten zwecks Datenschutz und Joint-Controller Vertrag unterzeichnet haben.

Weitere Aufnahmen sind vorgesehen und werden anhand der bereits erfüllten Szenarien und des Bedarfs aus dem Projekt geplant.

Zudem hat Valeo als Leiter des AP 4.4 die Aufnahmekampagne mit dem Partner AVL abgestimmt. Zusätzlich wird die synthetische Datenerzeugung mit den Partnern DLR und FZI koordiniert. Hierfür hat Valeo den Datenbedarf und die Anforderungen für synthetische Daten bei den Partnern abgefragt. Da die Mittel von FZI und DLR für die Erzeugung synthetischer Daten nicht für die Erfüllung der Projektbedürfnisse ausreichen, sind auch die Bereitschaft sowie die technische Umsetzbarkeit einer synthetischen Datenerzeugung bei den Partnern abgefragt worden. Da die Fortschritte in diesem Themenkomplex bisher hinter der Zeitplanung zurückgeblieben sind, ist für den nächsten Berichtszeitraum die Working Group Synthetic Data Creation gegründet worden.

Stand der Arbeiten (30.6.2023)

Im Berichtszeitraum 01.01.2023 - 30.06.2023 hat Valeo als Leiter des Arbeitspaketes 4.4 die Arbeiten an der synthetischen Datenerzeugung durch die Einführung der Arbeitsgruppe “Synthetic Data” vorangetrieben. Die Gruppe trifft sich wöchentlich. Valeo leitet und moderiert diese Arbeitsgruppe. Im Berichtszeitraum sind Lizenzen für den AVL Scenario Designer an interessierte Partner vergeben worden. Zusätzlich wurde der Status bei der Erstellung von Szenarien überprüft, wodurch einige Szenarien für die Erzeugung synthetischer Daten erstellt werden konnten. Weitere Szenarien befinden sich noch in der Bearbeitung, konnten aber schon an Partner vergeben werden. Valeo hat hierfür auch selbst die Arbeiten an Szenario 1.6 begonnen. Mit einer Fertigstellung dieses Szenarios ist im nächsten Berichtszeitraum zu rechnen.

Tabelle 13: Status bei der Erstellung von synthetischen Szenarien

Use Case 1 - Pedestrian Detection under Occlusion			
Scenario ID	Requests	Status	Contributor
1.1	4	Available	AVL
1.1 variant - many pedestrians		Available	AVL
1.2	9	In Development	AVL
1.3	7	In Development	AVL
1.4	6	Not Available	
1.5	2	Not Available	
1.6	2	In Development	Valeo

Use Case 2 - Complex Lane Change			
Scenario ID	Requests	Status	Contributor
2.1	4	Not Available	
2.2	4	Not Available	
2.3	7	Not Available	FZI
2.4	9	Available	AVL
2.5	6	In Development	AVL
2.8	2	Not Available	
2.9	4	Not Available	
2.10	1	Not Available	
2.12	3	Not Available	
2.13	1	Not Available	

Use Case 3 - Controlled Rule Exception			
Scenario ID	Requests	Status	Contributor
3.1	2	Not Available	FZI
3.2	5	In Development	Bosch
3.3	2	Not Available	
3.4	1	Not Available	
3.5	2	Not Available	
3.6	3	Not Available	
3.8	2	Not Available	
3.10	2	Not Available	
3.12	2	Not Available	
3.13	2	Not Available	
3.15	3	Not Available	
3.18	2	Not Available	
3.19	2	Not Available	
3.20	2	Not Available	
3.21	2	Not Available	
3.22	3	Not Available	

Um die Standardisierung der synthetischen Daten im Projekt voranzutreiben, hat Valeo einen Vorschlag für ein umfassendes Datenformat erstellt. Dieses umfasst sowohl rohe Bild- und Punktwolkendaten, als auch eine Spezifikation für verschiedene daraus abgeleitete Daten, wie 2D- oder 3D-Bounding-Boxes, 2D-semantische Segmentierung für Kameras, 2D Instanzsegmentierung für Kameras, semantische Segmentierung und Instanzsegmentierung für Lidare, 3D Skelette und Körperteilsegmentierung.

Beim Thema Realdatenaufnahme musste Valeo den Lidar Sensor vorne in der Mitte am Fahrzeug aufgrund eines Defektes ersetzen. Hierfür war es nötig, die Stoßstange zu demontieren. Dies hatte zur Folge, dass die Kalibration für sämtliche Sensoren, die an dieser Stoßstange angebracht sind, erneuert werden musste.

Valeo hat die Sichtung und Überprüfung der aufgenommenen Daten fortgesetzt. Erste Daten stehen bereit und können im nächsten Berichtszeitraum an die mit Labeling beauftragte Firma übergeben werden, sobald die Ausschreibung dafür beendet ist.

Zuletzt ist das Thema Kartendaten für bereits aufgezeichnete Realdaten diskutiert worden, hierfür hat Valeo einen Vorschlag unterbreitet, bei dem Open Street Map Daten zu den Realdaten beigelegt werden, um zusätzlich Metainformationen zur Beschaffenheit von Straßen zur Verfügung zu stellen. Hierfür soll im nächsten Halbjahr einerseits der Bedarf geklärt werden und andererseits muss das Format harmonisiert werden, damit AVL und Valeo in diesem Zusammenhang die gleichen Daten liefern.


Stand der Arbeiten (31.12.2023)

Im Berichtszeitraum 01.07.2023 - 31.12.2023 hat Valeo als Leiter des Arbeitspaketes 4.4 die Arbeiten an der synthetischen Datenerzeugung mithilfe der wöchentlichen Arbeitsgruppe "*Synthetic Data*" weiter vorangetrieben. Valeo leitet und moderiert diese Arbeitsgruppe. Darin ist der Status bei der Erstellung von Szenarien überprüft worden, wodurch weitere Szenarien für die Erzeugung synthetischer Daten erstellt wurden.


Im Bereich der Realdatenaufnahme hat Valeo seine Aufnahmen abgeschlossen. Es sind etwa 220 Sequenzen zusätzlich aufgezeichnet worden. Die Daten liegen im Projektformat vor und wurden in den gemeinsamen Projektspeicher, der von Capgemini zur Verfügung gestellt wird, hochgeladen. Capgemini Outsourcing hat die Ausschreibung für den GUA 3 gewonnen und wird sich im nächsten Berichtszeitraum der Annotierung der Realdaten annehmen. Valeo kümmert sich hierbei um die Auswahl der zu annotierten Daten.

Wie im vorhergehenden Berichtszeitraum bereits diskutiert, hat Valeo die Arbeiten an einer Kartendatenextraktion für die aufgezeichneten Realdaten gestartet. Das Vorgehen hierfür ist in regelmäßigen Meetings mit AVL abgestimmt worden. AVL hat eigene Untersuchungen durchgeführt, so dass am Ende ein gemeinsames Vorgehen standardisiert werden kann.

Als Ausgangspunkt für die Straßenkartendatenextraktion werden die GNSS-Daten der Aufzeichnungsfahrzeuge verwendet. Dann wird für eine gewisse Anzahl an Punkten ein Ausschnitt aus der OpenStreetMap einer Open-Source Karte heruntergeladen, sodass eine gewisse Umgebung zur Fahrzeugtrajektorie heruntergeladen wird.



Die heruntergeladenen Ausschnitte der OpenStreetMap werden daraufhin nach den für das Projekt interessanten Inhalten gefiltert und in eine gemeinsame Datei fusioniert. Anschließend werden die OpenStreetMap-Daten in das XODR-Format (ASAM OpenDRIVE) konvertiert. Dieses Format beinhaltet Straßendaten, wie zum Beispiel Ampeln und die Verknüpfung von Straßenelementen insbesondere an Kreuzungen. Dieses wird häufig benutzt um Straßennetze standardisiert zu repräsentieren.




Die Arbeiten an der Extraktion solcher Kartendaten stehen kurz vor der Vollendung. Geplant sind noch die Optimierung der Datenabfrage aus der OpenStreetMap, sowie eine hochwertige Konvertierung in das XODR-Format. Im vergangenen Berichtszeitraum ist dafür ein erster Proof-Of-Concept erstellt worden, der auf vielversprechende Weise zeigt, dass mit einfachen Mitteln eine große Anzahl sinnvoller Metadaten extrahiert werden kann.

Stand der Arbeiten (31.3.2024)

Im Berichtszeitraum 01.01.2024 - 31.03.2024 hat Valeo als Leiter des Arbeitspaketes 4.4 die Arbeiten mithilfe des wöchentlichen Regeltermins weiter vorangetrieben. Valeo leitet und moderiert diesen Regeltermin. Valeo hat zusammen mit AVL und Capgemini die letzten Details zur Annotierung geklärt.

Der letzte verbliebene Arbeitspunkt für Valeo in diesem Arbeitspaket ist die Finalisierung der Kartendatenextraktion. Im vorhergehenden Berichtszeitraum ist ein Proof-Of-Concept erreicht worden. Dieses Ergebnis ist nun soweit vorangetrieben worden, dass die erwartete Qualität für alle Aufnahmen sichergestellt werden kann. Zur Optimierung der Fläche, die aus der OpenSTREETMAP heruntergeladen werden muss hat Valeo herausgefunden, dass es sinnvoller ist, eine quadratische Bounding Box für die GNSS Punkte herunterzuladen, als einen Kreis. Der Grund dafür ist, dass Straßen in der Regel relativ gerade verlaufen und Kreuzungen häufig ungefähr einen 90° Winkel darstellen. Dadurch ist sichergestellt, dass auch relevante Attribute der Straße, wie Radwege oder Gehsteige, vollständig erfasst werden. Das folgende Bild veranschaulicht, wie die

Gebiete aus der OpenSTREETMAP ausgewählt werden, um Kartendaten zu einer Trajektorie, bestehend aus GNSS Punkten des Fahrzeugs, herunterzuladen



Um die Qualität bei der Extraktion der OpenDRIVE Karte aus den OpenSTREETMAP Daten zu verbessern, sind verschiedene Konverter-Funktionen aus verschiedenen Python-Bibliotheken ausprobiert und verglichen worden. Hier hat sich die Konverter-Funktion von SUMO durchgesetzt. Hier ist es möglich, dass die einzelnen Fahrspuren an komplexen Kreuzungen korrekt verknüpft werden und auch Informationen, wie eine vorhandene Ampel, richtig in die OpenDRIVE Karte übernommen werden.

Damit sichergestellt werden kann, dass das aufgeführte Vorgehen auch für die ganze Aufnahmekampagne funktioniert, haben Valeo und AVL jeweils exemplarisch charakteristische Aufnahmen validiert. Hierbei handelt es sich um Aufnahmen im urbanen Kontext, in Wohngebieten und auf Autobahnen. Um die Kartenextraktion zu validieren, ist die Geometrie der Straßen in der erzeugten Karte mit der echten Straßengeometrie abgeglichen worden. Zusätzlich ist die Korrektheit der Darstellung der einzelnen Fahrspuren geprüft worden. Hierfür ist entscheidend, dass einerseits alle Spuren abgebildet sind, und andererseits, dass die Spuren auch richtig verknüpft sind. Abschließend ist validiert worden, dass auch die Straßeninfrastruktur korrekt

abgebildet ist. Hierzu gehören Auf- und Abfahrten. Die Validierung einer Autobahn-Karte wird in der folgenden Abbildung veranschaulicht.





Abbildung 89: Oben sieht man hier die Ausschnitte, die aus der OpenSTREETMAP heruntergeladen worden sind. Unten ist die Visualisierung der OpenDRIVE Karte in der SUMO GUI abgebildet.

3.1.4.5 AP4.5 Evaluation und Demonstration

Aufgaben von Valeo

- Integration der entwickelten Methoden in den Demonstrator.
 - Selektion geeigneter in TP1-3 entwickelter Methoden zur Präsentation im Demonstrator im laufenden Projekt zur testweisen Evaluation.

Stand der Arbeiten (30.6.2021)

Der Beginn der Arbeiten für AP4.5 ist laut Vorhabenbeschreibung erst für den 1. Oktober 2021 angesetzt und damit nicht im Berichtszeitraum.

Stand der Arbeiten (31.12.2021)

Das AP4.5 wurde im Oktober 2021 fristgerecht gestartet. Valeo hat sich in den ersten Monaten mit der Abstimmung der hausinternen Arbeiten im AP1.1 und AP1.2 beschäftigt. Nach derzeitiger Planung ist eine projektweite Demonstration der Arbeiten zur LiDAR-Objekterkennung aus dem AP1.1 geplant. Die technischen Einzelheiten sind dem entsprechenden Berichtsteil zu entnehmen.

Stand der Arbeiten (30.6.2022)

In Anlehnung an die Kundenfunktion AVP simulieren wir Parkszenarios in CARLA. Das AVP-System enthält mehrere Fischaugenkameras, die zur Erkennung und Verfolgung von Fußgängern und Fahrzeugen verwendet werden. Die Trajektorie des Ego-Fahrzeugs wird anhand der Positionen von Fußgängern und Fahrzeugen geregelt.

Zuerst werden die Straße und der Parkplatzbereich mithilfe der Blender-Software inklusive dem Blender-Fahrszenario-Erstellungs-Add-on²² erstellt. Durch die Verwendung des Add-Ons in Blender können wir eine Straße erstellen und sie in die Dateiformate OpenDRIVE (XODR-Datei) und Filmbox (FBX-Datei) exportieren. Abbildung 90 zeigt den Untergrund des Standorts Kronach in Blender.




Abbildung 90: Parkplatz des Standorts Kronach in Blender.

Um die Parkkarte in CARLA aufzunehmen, platzieren wir die XODR- und FBX-Dateien des Parkplatzes im Ordner „Import“ im CARLA-Installationsverzeichnis und führen dann das Skript „Import.py“ aus dem Ordner „Util/BuildTools“ aus. Wir können den Paketnamen definieren, indem wir dem `—package`-Argument einen Namen geben. Der Standardpaketname ist `map_package`. Den Paketordner findet sich unter `„/Unreal/CARLAUE4/Content“`.

Nachdem wir den Parkplatzplan in CARLA haben, importieren wir die 3D-Modelle der Gebäude als FBX-Dateien. Im CARLA Editor können wir die Dateien einfach in das Ansichtsfenster ziehen und die Positionen der Modelle entsprechend festlegen. Abbildung 91 zeigt das Ergebnis nach dem Import in den Unreal Editor.

²²<https://github.com/johschmitz/blender-driving-scenario-creator>




Abbildung 91: 3D-Modell der Gebäude am Valeo Standort in Kronach im Unreal Editor.

Als nächstes müssen wir die Fischaugenkameras zur Karte hinzufügen. Da in CARLA standardmäßig keine Fischaugenkameras verfügbar sind, nehmen wir zuerst 2D-Bilder mit einer Lochkamera auf.

Die Positionen der Kameras werden mithilfe der Python-CARLA-API entsprechend festgelegt. Da wir die intrinsischen Parameter der Fischaugenkamera in AVP und der Lochkamera in CARLA kennen, können wir eine Umrechnung für die beiden Kameras erstellen. Durch Aufrufen der OpenCV-Remap-Funktion konvertieren wir das Lochkamerabild in das Fischaugenbild. Das Ergebnis davon ist jedoch fehlerhaft, da das FOV (Abkürzung für „field of view“, d.h. der Sichtbereich des Sensors) und die Brennweiten der Lochkamera nicht mit denen von Fischaugenkamera übereinstimmen. Wir können das FOV der Lochkamera in CARLA nicht größer als 180 Grad einstellen. Andererseits beträgt das FOV der Fischaugenkamera aus dem realen AVP-System 195 Grad. Abbildung 92 zeigt das simulierte Fischaugenbild in CARLA.



Abbildung 92: Simuliertes Fisheye-Bild in CARLA.

Für die zukünftige Arbeit werden wir sechs als Würfel angeordnete Lochkameras verwenden, um ein 360-Grad-Bild zu erstellen. Dann wenden wir das Fischaugen-Verzerrungsmodell auf dieses 360-Grad-Bild an. Alle Pixel außerhalb des FOV der Fischaugenkamera werden schwarz gerendert. Alle innenliegenden Pixel unterliegen einem Verzerrungseffekt.

Stand der Arbeiten (31.12.2022)

Fisheye-Bilderzeugung in CARLA

Unsere ersten Ansätze zur Modellierung einer Fischaugenkamera (Fisheye) basierten auf der Transformation des Bildes einer Lochkamera (Pinhole). Das so erzeugte Bild kann jedoch nicht das tatsächlich Fisheye-Bild der echten Kamera darstellen. Daher implementieren wir nun das Fischaugen-Sensormodell direkt in der Simulationssoftware CARLA.

Wir verwenden ein Poly4-Fisheye-Sensormodell. Die intrinsischen Parameter erhalten wir aus unserem Kamerakalibrierungsprozess. Das Poly4-Modell verwendet ein Polynom 4. Grades, um die Verzerrungen von Fisheye-Objektiven darzustellen. Für das Modell gehen wir davon aus, dass alle Projektionen einen einzigen Punkt kreuzen (d. h. die zentrale Projektion), der die Position des Kamerakoordinatenursprungs definiert. Die Ausrichtung des Kamerakoordinatensystems ist wie folgt definiert. Die z-Achse ist auf die Hauptachse der Kamera ausgerichtet. Die beiden anderen orthogonalen Richtungen (x, y) entsprechen den Achsen der Bildebene. Abbildung 93 zeigt das Kamerareferenzbild und die Bildebene.




Abbildung 93: Das Kamerareferenzbild und die Bildebene.

Nachfolgend sind die Projektions- und Unprojektionsfunktionen des Modells aufgeführt.

Projektionsfunktion

$$\begin{aligned}\pi(\mathbf{x}, \mathbf{i}) &= \begin{bmatrix} r * \cos \theta \\ r * \sin \theta * P_{xAspectRatio} \end{bmatrix} + \begin{bmatrix} c_x \\ c_y \end{bmatrix} \\ \theta &= \arctan 2(y, x) \\ \alpha &= \frac{\pi}{2} - \arctan 2(z, \sqrt{x^2 + y^2}) \\ r &= d(\alpha) = c_1 * \alpha + c_2 * \alpha^2 + c_3 * \alpha^3 + c_4 * \alpha^4\end{aligned}$$

$P_{xAspectRatio}$ ist das Pixel-Seitenverhältnis. Die Werte c_1 , c_2 , c_3 und c_4 sind die Polynomkoeffizienten. Die Werte c_x und c_y sind der Versatz zwischen dem Mittelpunkt der Bildebene und dem Kamerazentrum. Die Werte $P_{xAspectRatio}$, c_1 , c_2 , c_3 , c_4 , c_x und c_y erhalten wir durch den Kalibrierungsprozess.

Unprojektionsfunktion

$$\begin{aligned}\pi^{-1}((u, i)) &= \begin{bmatrix} m_x \\ m_y \\ \frac{r}{\tan \alpha} \end{bmatrix}, \alpha > \frac{\pi}{4} \\ &= \begin{bmatrix} \tan \alpha * \cos \alpha \\ \tan \alpha * \sin \alpha \\ 1 \end{bmatrix}, \alpha \leq \frac{\pi}{4} \\ m_x &= u - c_x \\ m_y &= (v - c_y) * P_{xAspectRatio} \\ r_u &= \sqrt{m_x^2 + m_y^2} \\ \alpha &= d^{-1}(r_u)\end{aligned}$$

Die u- und v-Werte sind die Pixelkoordinatenwerte in x- bzw. y-Richtung.

Fisheye-Bild der realen Umgebung

Abbildung 94 zeigt das Fisheye-Bild des Valeo-Hauptgebäudes in Kronach. Das Bild wurde von einer Kamera des AVP-Systems aufgenommen. Der Videostream dieser Kamera wird für die Objekterkennung und -verfolgung verwendet. Wir zeigen das Bild als Referenzbild.



Abbildung 94: Fisheye-Bild des Valeo-Büros in Kronach.

Fisheye-Bild in CARLA

Bei CARLA erfolgt die Implementierung der Projektions- und Unprojektionsfunktionen im Simulatorteil, der sich auf der Serverseite befindet. Auf der Client-Seite müssen wir jedoch auch neue Sensordaten hinzufügen. Außerdem fügen wir sowohl auf der Server- als auch auf der Client-Seite einen neuen Serialisierer hinzu, um die von der Kamera erzeugten Daten zu serialisieren und zu deserialisieren. Abbildung 95 zeigt die CARLA-Kommunikationspipeline und Abbildung 96 zeigt das Ergebnis des Fischaugenbildes in CARLA.




Abbildung 95: CARLA-Kommunikationspipeline ²³.



Abbildung 96: Fisheye-Bild von CARLA des 3D-Modells des Valeo-Büros in Kronach.

²³ https://carla.readthedocs.io/en/latest/tuto_D_create_sensor/

Als Nächstes generierten wir den Fischaugenbild-Datensatz zum Testen unserer Wissensextraktionsannahme. Zunächst definieren wir die Liste der Farben des Fahrzeugs, die 30 RGB-Farbwerte enthält. Dann stellen wir das parkende Auto auf der gegenüberliegenden Seite der Fisheye-Kamera auf. Alle 5 Sekunden ändern wir die Farbe des Autos und nehmen das Bild auf, bis alle Farben angewendet wurden. Am Ende haben wir 30 png-Bilddaten.

Die Yolact-Objekterkennung wird hier verwendet, um unsere Vermutung zu validieren. Jedes Bild wird mit Yolact zur Objekterkennung mit Instanzsegmentierung verarbeitet. Die Bilddaten mit den erkannten Objekten werden zusätzlich mit einem Graphen generiert, der die Beziehung zwischen der Objekterkennungskonfidenz und den Farbwerten zeigt, was in diesem Fall die Wissensextraktion darstellt. Abbildung 97 zeigt den Arbeitsablauf der Wissensextraktion.




Abbildung 97: Workflow-Diagramm der Wissensextraktion.

Stand der Arbeiten (30.6.2023)

Erzeugung von Fisheye-Bildern im Carla-Docker-Container

In unserem letzten Zwischenbericht haben wir ein Poly4-Fisheye-Sensormodell in Carla implementiert. Dieses poly4-Fischaugenmodell stellt eine polynomiale Verzerrung eines Fischauges dar. Die Demonstratorimplementierung erfolgt auf der CARLA-Serverseite und der Client-Seite. Auf der Serverseite verwenden wir den Scene-Capture-Würfel der Unreal-Engine, um 360-Grad-Bilder zu erfassen und das Bild mit Hilfe von Shadern auf das Fisheye-Bild abzubilden. Diese Implementierung erfolgt durch Modifizierung des Shader- und cpp-Codes des ursprünglichen CARLA Quellcodes auf Server- und Client-Seite.

Da der Docker Container im Demonstrator die Standardversion von CARLA Release 0.9.13 enthält, können wir den CARLA Quellcode nicht ändern und unser Fischaugenmodell nicht ohne Weiteres einsetzen. Daher müssen wir einen alternativen Weg finden, um den Fischaugenbilddatensatz im

Demonstrator zu erzeugen. Eine Methode, die wir bereits bei Valeo verwendet haben, ist das Cube Mapping.

Abbildung 98 zeigt den Abbildungsprozess der Pixel des Cubemap-Bildes auf dem Fisheye-Bild. Wir konstruieren den Einheitswürfel, der dem Cubemap-Bild entspricht. Jede Seite des Würfels ist das Bild der Lochkamera mit einem 90-Grad-Sichtfeld (FOV). Hier haben wir fünf Lochkameras, die nach vorne, oben, unten, links und rechts zeigen.




Abbildung 98: Abbildung der Pixel des Cubemap-Bildes auf das Fisheye-Bild²⁴.

Aus den lokalen Koordinaten der einzelnen Lochkamerabilder erstellen wir die Cubemap gemäß Abbildung 99. Die Flächen 1, 2, 3, 4 und 5 stehen jeweils für die rechte, obere, linke, untere und vordere Bildebene der Kamera. In Abbildung 99 und Abbildung 100 sind u und v die lokalen Koordinaten der Lochkamerabilder. Wir transformieren diese lokalen Koordinaten in die globalen Koordinaten (x , y , z) der Cubemap gemäß Abbildung 100.

²⁴ A. R. Sekkat, Y. Dupuis, V. R. Kumar, H. Rashed, S. Yogamani, P. Vasseur, and P. Honeine, "Synwoodscape: Synthetic surround-view fisheye camera dataset for autonomous driving," *IEEE Robotics Automation Letters*, 2022




Abbildung 99: Koordinatensystem für eine Cubemap nach Alan Watt²⁵.

Mit der gleichen Projektionsfunktion aus dem letzten Zwischenbericht können wir eine Nachschlagetabelle zwischen den lokalen Pixelkoordinaten des Lochkamerabildes und den lokalen Pixelkoordinaten des Fischaugenkamerabildes erstellen.




Abbildung 100: Entsprechende Cubemap zur Abbildung 99.

²⁵ Alan Watt and Mark Watt, *Advanced Animation and Rendering Techniques: Theory and Practice*, ACM Press, 1992. ISBN 978-0201544121

Projektionsfunktion

$$\begin{aligned}\pi(\mathbf{x}, \mathbf{i}) &= \begin{bmatrix} r * \cos \theta \\ r * \sin \theta * P_{xAspectRatio} \end{bmatrix} + \begin{bmatrix} c_x \\ c_y \end{bmatrix} \\ \theta &= \arctan 2(y, x) \\ \alpha &= \frac{\pi}{2} - \arctan 2(z, \sqrt{x^2 + y^2}) \\ r &= d(\alpha) = c_1 * \alpha + c_2 * \alpha^2 + c_3 * \alpha^3 + c_4 * \alpha^4\end{aligned}$$

$P_{xAspectRatio}$ ist das Pixel-Seitenverhältnis. Die Werte c_1 , c_2 , c_3 und c_4 sind die Polynomkoeffizienten. Die Werte c_x und c_y sind der Versatz zwischen dem Mittelpunkt der Bildebene und dem Kamerazentrum. Die Werte $P_{xAspectRatio}$, c_1 , c_2 , c_3 , c_4 , c_x und c_y erhalten wir durch den Kalibrierungsprozess. x , y , z sind die globalen Koordinaten der Cubemap.

Fisheye-Bild in Carla

Das Ergebnis des Mappings ist in Abbildung 101 zu sehen, die das RGB-, Tiefen- und semantische Bild zeigt. Der Vorteil dieser Methode ist, dass wir ein RGB-, Tiefen- und semantisches Bild erstellen können, ohne den Quellcode von CARLA zu ändern. Der Nachteil dieser Methode ist jedoch, dass wir fünf Kameras auf der Client-Seite erstellen müssen, was zu einer hohen Arbeitsbelastung von GPU und CPU führen und die Simulationszeit verlangsamen kann.




Abbildung 101: RGB-, Tiefen- und semantische Fischaugenbilder.

Stand der Arbeiten (31.12.2023)

In unserem letzten Zwischenbericht haben wir eine Methode zur Erstellung eines Fisheye-Bildes aus einem Cubemap-Bild vorgeschlagen. Diese Methode erleichtert uns die Erstellung eines Fisheye-Bildes ohne jegliche Modifikation der Unreal-Engine und des CARLA-Quellcodes aus dem offiziellen CARLA-Repository.

Bei der Ausgabe des Fisheye-Bildes haben wir festgestellt, dass es dunkle Nähte zwischen den verbundenen Bereichen zweier Bilder gibt. Daher haben wir dieses Problem untersucht und herausgefunden, dass es durch die Nachbearbeitung in CARLA verursacht wird.

Aufgrund verschiedener Nachbearbeitungseffekte, die vom CARLA-Simulator zur Verbesserung des Fotorealismus aktiviert und von der Unreal-Engine auf die gerenderte Landschaft angewendet werden, weisen die zusammengesetzten Bilder auffällige Artefakte um die Nähte herum auf. Zusätzliche Artefakte werden durch zeitliches Anti-Aliasing verursacht, das in Regionen der zusammengesetzten Bilder, die von verschiedenen Kameras stammen, zu einer uneinheitlichen Ausgabe führt. Dies führt insbesondere dazu, dass der zentrale Bereich von Fisheye-Bildern unschärfer erscheint als die peripheren Bereiche, wenn sich das Fahrzeug bewegt, unabhängig von den Einstellungen für die Bewegungsunschärfe.

Um diese Probleme so weit wie möglich abzuschwächen, ohne den Fotorealismus und die Bildqualität des synthetischen Bildes zu sehr zu beeinträchtigen, haben wir die Konfigurationsdatei der Unreal Engine geändert: 'Unreal/CARLAUE4/Config/DefaultEngine.ini'.

Im Abschnitt [/Script/Engine.RendererSettings] ändern wir die folgenden Zeilen.

```
r.TextureStreaming=False          # default: True
r.DefaultFeature.AntiAliasing=1    # default: 2 (0: None, 1: FXAA, 2: TemporalAA, 3: MSAA)
```

Im Folgenden wird erklärt, wie die einzelnen Konfigurationsparameter funktionieren.

1. **r.TextureStreaming=False**: TextureStreaming ist eine Technik, die zum dynamischen Laden und Entladen von hochauflösenden Texturen auf der Grundlage der Position des Spielers in der Spielwelt verwendet wird. Wenn **r.TextureStreaming** auf False gesetzt ist, bedeutet dies, dass Texture-Streaming deaktiviert ist. Dies kann sich auf die Speichernutzung und die Ladezeiten auswirken, kann aber in Szenarien nützlich sein, in denen man den Overhead beim Laden/Entladen von Texturen minimieren möchte oder wenn man ein System mit begrenzten Ressourcen hat.
2. **r.DefaultFeature.AntiAliasing=1**: Diese Zeile steuert die standardmäßige Anti-Aliasing-Methode, die im Renderer verwendet wird. Anti-Aliasing ist eine Technik, mit der visuelle Artefakte wie gezackte Kanten in Computergrafiken reduziert werden. Die möglichen Werte sind:
 - a. 0: No anti-aliasing (None)
 - b. 1: FXAA (Fast Approximate Anti-Aliasing)
 - c. 2: TemporalAA (Temporal Anti-Aliasing)

d. 3: MSAA (Multi-Sample Anti-Aliasing)

Die Einstellung **r.DefaultFeature.AntiAliasing=1** bedeutet, dass die Standard-Anti-Aliasing-Methode FXAA ist. FXAA ist eine schnelle, aber weniger genaue Anti-Aliasing-Methode im Vergleich zu anderen. Entwickler können aufgrund von Leistungsüberlegungen und Anforderungen an die visuelle Qualität verschiedene Anti-Aliasing-Methoden wählen. Temporales AA mildert wirksam das Problem des Flackerns und/oder der gezackten Kanten und Pixel, erzeugt jedoch Unschärfe/Ghosting-Artefakte. Nicht-temporale AA wie FXAA verursacht keine Unschärfe- oder Ghosting-Artefakte, löst aber nicht das Flimmern. Eine effektive Lösung für die Probleme der temporalen AA auf Kosten eines erhöhten Rechenaufwands bietet UE, wenn Geschwindigkeitspuffer in den Rendering-Einstellungen aktiviert sind.

Wir fügen auch diese Zeilen in diesem Abschnitt an.

```
r.BlackBorders=0
r.DepthOfFieldQuality=0
r.DisableDistortion=1
r.MotionBlurQuality=0
r.SceneColorFringeQuality=0 # Chromatic aberration
r.Tonemapper.Quality=0      # Vignette
```

Die Einzelheiten der Konfigurationsparameter werden im Folgenden erläutert.

1. **r.BlackBorders=0**: Diese Einstellung steuert, ob schwarze Ränder auf das gerenderte Bild angewendet werden. Ein Wert von 0 bedeutet normalerweise, dass schwarze Ränder deaktiviert sind, während ein Wert von 1 sie aktivieren würde. Mit dieser Einstellung wird das Aussehen der Ränder um das gerenderte Bild gesteuert.
2. **r.DepthOfFieldQuality=0**: Die Schärfentiefe (DOF) ist ein Nachbearbeitungseffekt, der die Art und Weise simuliert, wie eine Kamera Objekte in einer bestimmten Entfernung fokussiert, wobei Objekte im Vorder- und Hintergrund verschwimmen. Die Einstellung **r.DepthOfFieldQuality** steuert die Qualitätsstufe dieses Effekts. Ein Wert von 0 bedeutet oft, dass DOF deaktiviert ist.
3. **r.DisableDistortion=1**: Diese Einstellung steuert, ob die Linsenverzerrung auf das gerenderte Bild angewendet wird. Ein Wert von 1 bedeutet in der Regel, dass die Verzerrung deaktiviert ist, während sie bei 0 aktiviert ist. Die Verzerrung ist ein Linseneffekt, der die Biegung des Lichts in einer Linse simulieren kann.
4. **r.MotionBlurQuality=0**: Bewegungsunschärfe ist ein Effekt, der die Unschärfe von sich schnell bewegenden Objekten in einer Szene simuliert. Die Einstellung **r.MotionBlurQuality** bestimmt die Qualitätsstufe der Bewegungsunschärfe. Ein Wert von 0 bedeutet häufig, dass die Bewegungsunschärfe deaktiviert ist.
5. **r.SceneColorFringeQuality=0**: Diese Einstellung steuert die Qualität des Effekts "Farbsaum". Der Farbsaumeffekt, auch bekannt als chromatische Aberration, ist ein Effekt, bei dem verschiedene Farben an den Kanten von Objekten in einem Bild verschoben werden. Ein Wert von 0 bedeutet normalerweise, dass dieser Effekt deaktiviert ist.

6. **r.Tonemapper.Quality=0**: Tonemapping ist eine Technik, mit der HDR-Werte (High Dynamic Range) auf einen anzeigbaren Bereich abgebildet werden. Die Einstellung **r.Tonemapper.Quality** steuert die Qualitätsstufe des Tonemappings. Ein Wert von 0 bedeutet häufig, dass das Tone Mapping deaktiviert ist.

Abbildung 102 zeigt auf der linken Seite das Fisheye-Bild mit der Standard-Nachbearbeitung von CARLA und auf der rechten Seite das Fisheye-Bild mit der modifizierten Nachbearbeitung. Hier können wir kaum dunkle Nähte im Bild auf der rechten Seite sehen.



Abbildung 102: Fisheye-Bild mit der Standard-Nachbearbeitung von CARLA (links) und Fisheye-Bild mit der modifizierten Nachbearbeitung (rechts)

Um das Ergebnis der modifizierten Nachbearbeitung zu bestätigen, wandeln wir die beiden obigen Bilder in Graustufenbilder um und stellen ihr Histogramm dar. Um das Ergebnis deutlich zu machen, ignorieren wir die Pixel mit dem Wert Null (komplett schwarz). Abbildung 103 zeigt den Histogrammvergleich zwischen den Graustufenbildern der Standard-Nachbearbeitung (rot) und der modifizierten Nachbearbeitung (blau). Es ist zu erkennen, dass sich das Histogramm des modifizierten Nachbearbeitungsbildes mehr in Richtung 255 verschiebt (weiße Pixel).




Abbildung 103: Histogrammvergleich der Graustufenbilder zwischen der Standardnachbearbeitung (rot) und der modifizierten Nachbearbeitung (blau).

Stand der Arbeiten (31.3.2024)

Die im Arbeitspaket 4.5 beschriebenen Aufgaben wurden im vergangenen Berichtszeitraum erfolgreich abgeschlossen.

Insbesondere wurden bestimmte Ergebnisse dieser Arbeit in ein Poster integriert, das auf der Abschlussveranstaltung des Projekts am 21. März 2024 in Frankfurt am Main vorgestellt wurde.

Im nächsten geförderten Projekt, z.B. jbData, NxtAIM, an dem Valeo beteiligt ist, wird die Simulations- und Validierungsaufgabe einer Operational Design Domain (ODD) unter Verwendung einer Simulations-Toolchain weitergeführt. Anstelle einer traditionellen Simulationssoftware, die auf einer Game/Rendering Engine basiert, wird die generative KI für die Simulationsaufgabe weiterentwickelt.

3.1.5 TP5: Projektmanagement und Ergebnisverbreitung

Tabelle 14: Struktur von TP5

TP/AP	Titel	Leitung
TP5	Projektmanagement und Ergebnisverbreitung	Continental
AP5.1	State-of-the-Art Research	fortiss
AP5.2	Management und Koordination	Continental
AP5.3	Ergebnisverbreitung	Continental
AP5.4	Kommunikation mit Gremien	Fraunhofer FOKUS

3.1.5.1 AP5.1 State-of-the-Art Research

Aufgaben von Valeo

- Recherche zu wissensbasierten Methoden für die Sensordatenverarbeitung
 - Mit Fokus auf Objekterkennung
 - Mit Fokus auf Sensoreigendiagnose

Stand der Arbeiten (30.6.2021)

Für den State-of-the-Art Bericht von KI Wissen hat Valeo durch die Erstellung und Überprüfung einzelner Textpassagen beigetragen. Hierfür wurde eine intensive Literaturrecherche zu wissensbasierter KI durchgeführt. Als Industriepartner legt Valeo hier den Schwerpunkt auf Ansätze mit praktischem Nutzen für zukünftige Entwicklungs- und Serienprojekte im Automobilsektor.

Stand der Arbeiten (31.12.2021)

Im Rahmen dieser Berichtsphase hat Valeo erneut durch die Literaturrecherche zu wissensbasierten KI Methoden und der Erstellung einzelner Textpassagen zum State of the Art

Paper beigetragen. Des Weiteren hat Valeo den bestehenden State of the Art Bericht kritisch geprüft.

Stand der Arbeiten (30.6.2022)

Nach Veröffentlichung des ersten Entwurfs des State-of-the-Art Papers²⁶ von KI Wissen gab es von Valeo Seite keine weiteren Beiträge.

3.1.5.2 AP5.2 Management und Koordination

Aufgaben von Valeo

- TP3-Leitung
 - Organisation und Durchführung von TP-Workshops
 - Koordination von Beiträgen aus TP3 zu Zwischen- und Jahresberichten

Stand der Arbeiten (30.6.2021)

Im Berichtszeitraum hat Valeo die Leitung von TP3 übernommen. Dabei wurden wöchentliche TP3-Treffen jeweils montags um 11 Uhr angesetzt. Im wöchentlichen Wechsel wurden in diesem Termin die Plenums-Treffen und die AP-Treffen durchgeführt. In den Plenums-Treffen kommen alle TP3-Partner unter Leitung von Valeo zusammen. Der Fokus liegt dabei auf organisatorischen Themen, wie die Arbeitsaufträge der Partner für die Ergebnisse, die Interpretation und Planung der Partnerprojekte auf AP-Ebene im Vergleich zur Vorhabenbeschreibung und die Planung der TP3-Fortschritte auf TP-Ebene. Seit Projektstart wurden insgesamt 15 dieser Treffen durchgeführt. Darüber hinaus fanden 16 Treffen im TP3-Leitungskreis unter Leitung von Valeo statt. In den AP-Treffen wurde pro Termin einem Partner die Möglichkeit geboten, seine Arbeiten zu präsentieren. Dies ermöglichte eine tiefergehende Analyse der technischen Inhalte des jeweiligen Partners und eine kontinuierliche Sammlung und Bündelung der Arbeiten aller Partner.

Ein weiterer Höhepunkt erfolgte in der Darlegung der TP3-Inhalte durch Valeo im Kick-off Meeting von KI Wissen am 2. Februar 2021 inklusive Vortrag, Diskussionsrunde und anschließender Dissemination der Ergebnisse. Ein darauffolgender Kick-off innerhalb von TP3 wurde unter maßgeblicher Gestaltung, Moderation und Teilnahme von Valeo durchgeführt.

Den Status und die Ergebnisse aus TP3 wurde durch Valeo wöchentlich im PMT-Meeting vertreten. Hierbei lieferte Valeo Anregungen zu diversen Themen wie dem gesamten Planungsprozess in KI Wissen, der Organisation von Gitlab, welches die gemeinsame Plattform zur Entwicklung von Quellcode in KI Wissen bildet und dem projektweiten Einsatz der Simulationsumgebung Carla.

²⁶ Wörmann, Julian, et al. "Knowledge Augmented Machine Learning with Applications in Autonomous Driving: A Survey." arXiv preprint arXiv:2205.04712 (2022)

Stand der Arbeiten (31.12.2021)

Im Berichtszeitraum hatte Valeo die Leitung von TP3 inne. Dabei wurden wöchentliche TP3-Treffen jeweils montags um 11 Uhr angesetzt. Im wöchentlichen Wechsel wurden in diesem Regeltermin das Plenums-Treffen und die AP-Treffen durchgeführt. In den Plenums-Treffen kommen alle TP3-Partner unter Leitung von Valeo zusammen, was im Berichtszeitraum sechs Mal der Fall war. Darüber hinaus fanden 14 Treffen im TP3-Leitungskreis unter Leitung von Valeo statt.

Der Fokus in den Plenums- und den AP-Meetings liegt dabei auf organisatorischen Themen, wie der Interpretation und Planung der Partnerprojekte auf AP-Ebene im Vergleich zur Vorhabenbeschreibung, der Planung der TP3-Fortschritte auf TP-Ebene und der Planung der Ergebnisse E3.1.1 und E3.2.1 bis Ende November 2021. Diese Ergebnisse wurden fristgerecht erstellt, um ihrerseits in die Deliverables D1 "Catalogue, characterisation and representation of relevant domain knowledge for L3 to L5 driving functions" und D4 "Methods for data-independent validation of the predictions and decisions of an AI function" einzufließen. Diese Deliverables wurden in Kollaboration mit TP1 auf der Plattform Overleaf erstellt und bis Ende des vorliegenden Berichtszeitraumes dem Projekt als White Paper zur Verfügung gestellt.

In den AP-Treffen wurde pro Termin einem Partner die Möglichkeit geboten, seine Arbeiten zu präsentieren mit anschließender Diskussion. Zum Ende des Berichtszeitraums konnte jeder Partner mindestens einmal ein Thema präsentieren. Die nächste Runde an Vorträgen ist hier bereits für Q1 2022 geplant, um die weiteren Fortschritte der Partnerarbeiten zu verfolgen.

Ein weiterer Höhepunkt erfolgte am 30. November 2021 durch die Darlegung der TP3-Inhalte im zweiten Steuerkreistreffen von KI Wissen. Am generellen Vorgehen, dem aktuellen Status und den erzielten Ergebnissen von TP3 gab es keinerlei Beanstandung. Des Weiteren wird der TP3-Status durch Valeo wöchentlich im PMT-Meeting vertreten. Hierbei lieferte Valeo Anregungen zu diversen Themen wie den ersten Planungen des ersten Open-Project-Day von KI Wissen am 22. Februar 2022, der Organisation von kollaborativen Softwareentwicklungsprozesse, dem projektweiten Einsatz des Demonstrators von AVL und der Ausarbeitung der nötigen Prozesse zum Aufzeichnen, Labeln, Anonymisieren und Teilen von Realdaten im Zuge des GUA3 "Labeling". Zum letzten Punkt lieferte Valeo eine Präsentation mit nötigen Schritten als Diskussionsgrundlage.

Stand der Arbeiten (30.6.2022)

Im Berichtszeitraum hat Valeo die Leitung von TP3 inne. Am 22.02.2022 vollzog KI Wissen unter Beteiligung von TP3 erfolgreich den ersten Open-Projekt-Day mit einem internen Workshop am darauffolgenden Tag. In den drei Sessions zu den jeweiligen Use Cases von KI Wissen wurden insgesamt sechs Vorträge aus TP3 angeboten. Die entsprechenden Themen wurden dem Publikum in Kurzvorträgen dargelegt. Jedoch konnte sich in der anschließenden Abstimmung keines der Themen aus TP3 durchsetzen.

Im Berichtszeitraum wurden im TP3-Leitungskreis 9 Treffen und im TP3-Plenum mit allen Partnern 5 Treffen durchgeführt. Die bisherigen AP-Treffen wurden durch ein neues Workshop-Format ersetzt. Durch die Workshops reduzieren wir die Anzahl der Meetings pro AP und legen einen Fokus auf längere Sessions mit dedizierten inhaltlichen Themen. Dies ermöglicht tiefe Diskussionen zu spezifischen Inhalten mit den dazu passenden Experten der Partner aus KI Wissen.

In Summe liegt TP3 im Arbeits- und Zeitplan. Alle Ziele für den Berichtszeitraum wurden fristgerecht und vollständig erreicht. Daher wurden die Statusampeln aller APs in TP3 durch den TP3-Leitungskreis mit grün bewertet.

In Berichtszeitraum wurden bereits Workshops zu den Themen "Spatial Knowledge" und "Monitoring" angehalten. Die umfassend positiven Rückmeldungen lassen uns weiter an diesem Format festhalten für den anstehenden Berichtszeitraum.

Stand der Arbeiten (31.12.2022)

Im Berichtszeitraum hatte Valeo die Leitung von TP3 inne. In diesem Rahmen wurden im TP3-Leitungskreis 9 Treffen und im TP3-Plenum mit allen Partnern 3 Treffen durchgeführt. Die AP-Treffen wurden auch weiterhin durch ein Workshop-Format ersetzt. Durch die Workshops reduzieren wir die Anzahl der Meetings pro AP und legen einen Fokus auf längere Sessions mit dedizierten inhaltlichen Themen. Dies ermöglicht tiefe Diskussionen zu spezifischen Inhalten mit den dazu passenden Experten der Partner aus KI Wissen.

In Berichtszeitraum wurden Workshops zu den Themen "*Logic Representations*" (10.08.2022), "*Intermediate Evaluation/Metrics*" (07.11.2022) und "*TP3 SW Delivery*" (14.11.2022) abgehalten. Die umfassend positiven Rückmeldungen lassen uns für den anstehenden Berichtszeitraum weiter an diesem Format festhalten.

TP3 liegt im Arbeits- und Zeitplan. Alle Ziele für den Berichtszeitraum wurden fristgerecht und vollständig erreicht. Daher wurden die Statusampeln aller APs in TP3 durch den TP3-Leitungskreis mit grün bewertet.

Stand der Arbeiten (30.6.2023)

Im Berichtszeitraum hatte Valeo die Leitung von TP3 inne.

In diesem Rahmen wurden 9 Treffen im TP3-Leitungskreis, ein allgemeines Treffen im TP3-Plenum und 2 Plenums-Workshops mit allen Partnern zur Erarbeitung der TP3 Taxonomie-Matrix durchgeführt. Die AP-Treffen wurden auch weiterhin durch ein Workshop-Format ersetzt. Durch die Workshops reduzieren wir die Anzahl der Meetings pro AP und legen einen Fokus auf längere Sessions mit dedizierten inhaltlichen Themen. Dies ermöglicht tiefe Diskussionen zu spezifischen Inhalten mit den dazu passenden Experten der Partner aus KI Wissen.

TP3 liegt im Arbeits- und Zeitplan. Alle Ziele für den Berichtszeitraum wurden fristgerecht und vollständig erreicht. Daher wurden die Statusampeln aller APs in TP3 durch den TP3-Leitungskreis mit grün bewertet. Die Integration der in AP3.2 und AP3.3 entwickelten Ansätze in den Demonstrator unterliegt teilweise Verzögerungen. Diese sollen durch die kostenneutrale Verlängerung der Projektlaufzeit aufgeholt werden.

Stand der Arbeiten (31.12.2023)

Im Berichtszeitraum hatte Valeo die Leitung von TP3 inne.

In diesem Rahmen wurden 10 Treffen im TP3-Leitungskreis, ein allgemeines Treffen im TP3-

Plenum und einen Präsenz-Workshop mit allen Partnern in München durchgeführt. Im Rahmen des Präsenz-Workshops wurde in Vorträgen eine Übersicht zum aktuellen Entwicklungsstand bei den Partnern gegeben und darüber hinaus der Implementierungsstand für die Demonstrationen besprochen. Schließlich wurde noch über mögliche Beiträge der Partner zum nahenden Abschlussevent gesprochen. Für den Workshop konnten wir dankenswerterweise die Räumlichkeiten des Partners CapGemini unentgeltlich nutzen.

TP3 liegt im Arbeits- und Zeitplan. Alle Ziele für den Berichtszeitraum wurden fristgerecht und vollständig erreicht. Daher wurden die Statusampeln aller APs in TP3 durch den TP3-Leitungskreis mit grün bewertet.

Stand der Arbeiten (31.3.2023)

Im Berichtszeitraum hatte Valeo die Leitung von TP3 inne.

In diesem Rahmen wurden zwei Treffen im TP3-Leitungskreis durchgeführt. Dabei wurden vor allem die Präsentations- und Posterbeiträge der einzelnen Partner für das Abschlussevent koordiniert. Außerdem wurde für das Abschlussevent die Präsentation des TP3 mit Hilfe aller Partner erstellt, um einen Überblick über die Arbeiten im TP zu geben und auf die ausführlichen Präsentationen und Poster hinzuweisen.

Des Weiteren wurde die Erstellung der Abschlussberichte im TP3-Leitungskreis koordiniert.

TP3 liegt im Arbeits- und Zeitplan. Alle Ziele für den Berichtszeitraum wurden fristgerecht und vollständig erreicht.

3.2 Zahlenmäßiger Nachweis

Im Folgenden eine grobe Übersicht der Einhaltung der Kosten im Projekt. Mit Ausnahme der Reisekosten, liegt keine signifikante Abweichung (>20%) der Kosten zur ursprünglichen Planung vor.

Tabelle 15: Übersicht der bewilligten Kostenpositionen

Position	Benennung im Antrag (AZK)	Verwendung
F0837	Personalkosten	Bewilligt wurden 1.742.301,78 € an Personalkosten. Nachgewiesen und abgerechnet gem. der Zwischennachweise fielen 2.043.025,97 € an Kosten an. Die Abweichung der Soll-/Ist-Kosten beträgt 17,26 %.

F0838	Reisekosten	An Reisekosten sind 301,05 € angefallen. Bewilligt wurden Reisekosten in Höhe von 10.946,00 € (Vor Kürzungsantrag: 18.871 €). Wie schon in den Zwischenberichten zuvor berichtet, liegt der Grund u.a. im Minderbedarf der Reisekosten an den Corona bedingten Reisebeschränkungen und dem Ausweichen auf Online-Meetings.
F0847	Abschreibungen auf vorh. Spez. Anlagen	Geplant waren die Abschreibungen eines Sindoh 3D-Druckers, einer DSpace Motionsdesk (Wurde gem. Umwidmungsantrag gestrichen), eines Vector VT Systems und einem Rudi AGX. Die gesamten Abschreibungskosten betragen 41.019,22 €. Bewilligt wurden 38.449,84 €. Die Abweichung beträgt 6,67%.
F0850	Sonstige unmittelbare Vorhabenkosten	Bewilligt waren Kosten in Höhe von 119.038,22 €. Die IST-Kosten betragen 128.241,28 €. Somit liegt hier eine Abweichung in Höhe von 7,73 % vor. Grund hierfür ist z.B. die Position „GUA1 Verlängerung“. Hier sind zusätzliche Kosten in Höhe von 7.158,76 € entstanden, die zu Projektbeginn noch nicht eingeplant werden konnten und der Projektverlängerung um 3 Monate, vom 01.01.2024 - 31.03.2024, geschuldet sind.

Summa Summarum beträgt die Abweichung der gesamten Soll-/Ist-Kosten ~15,80 %. D.h. es entstanden im Projekt insgesamt Kosten in Höhe von 2.212.587,52 €. Bewilligt waren 1.910.735,84 €. Die entstandenen Mehrkosten gehen zu Lasten von Valeo. Somit hat sich der Eigenanteil entsprechend erhöht.

3.3 Notwendigkeit der Förderung

Die Valeo Schalter und Sensoren GmbH ist einer der führenden OES. In manchen Bereichen sogar Marktführer. Die Konkurrenz und der allgemeine Fortschritt im Bereich Automotive Sensorik sind groß. Um den Anschluss nicht zu verlieren, gilt es stets innovative und marktgerechte Produkte zu entwickeln. Ohne Forschung ist das nicht möglich, weshalb Valeo auch jährlich große Summen des jährlichen Umsatzes in die Forschung investiert. Im Zuge von öffentlichen Forschungsprojekten ist es zudem möglich mit den einschlägigen OEM und OES zusammenzuarbeiten und zielgerichtet den Bedürfnissen des Marktes Rechnung zu tragen. Viele Themen, die im Rahmen von KI Wissen bearbeitet wurden, können zudem nur gemeinschaftlich in dieser Größenordnung umgesetzt werden, wie z.B. der Zugriff auf gemeinsame Daten und die Beauftragung über gemeinschaftliche Unteraufträge.

3.4 Nutzen und Verwertbarkeit

Die folgende Tabelle zeigt die geplante Nutzung und Verwertung der Ergebnisse von KI Wissen.

Tabelle 16: Nutzung und Verwertung der Ergebnisse von KI Wissen

Projektergebnis/Inhalt	Nutzen/Verwertung
Konzepte und Implementierungen (Software) von Methoden zur Nutzung von Wissen für die Steigerung von Effizienz und funktionaler Güte und für die Plausibilisierung bzw. Absicherung von KI-Funktionen / Konzepte und Implementierungen von Methoden zur Extraktion von Wissen aus trainierten DL-Modellen	Verbesserte Sensorfunktionen wie Objekterkennung im Bereich Kamera, LiDAR, Radar und Ultraschall durch Verwendung wissensbasierter KI-Funktionen; höhere Erkennungsraten bei geringerer Fehleranfälligkeit. Darauf aufbauend leistungsfähigere Fahrerassistenzsysteme wie AEB oder Spurhalteassistent; Realisierung autonomer Fahrfunktionen bei Cruise4U oder Drive4U
Definition von Schnittstellen zwischen den Komponenten eines AD-Systems (inklusive Definition von Eingabe- und Ausgabeformaten für Komponenten sowie Systemmodell aller Komponenten, deren Schnittstellen und Verbindungen)	Schnellere Entwicklung von Sensor- und Fahrerassistenzfunktionen, insbesondere bei multimodaler Sensorintegration; einfachere Validierung durch definierte Schnittstellen
Reale und synthetische Datensätze für die Verifizierung und Validierung von KI-basierten AD-Komponenten	Multimodale Datensätze aus synthetischen und realen Daten sind universell für alle Sensorgenerationen und Einbaupositionen verwendbar; vereinfachte automatisierte Validierung von Fahrerassistenz- und autonomen Fahrfunktionen
Gütekriterien für das Bewerten der Qualität von KI-Komponenten und das Verhalten eines AD-Gesamtsystems	Entwicklung standardisierter Fahrfunktionen, die einheitlichen Gütekriterien entsprechen als Verkaufsargument; Wissensdatenbank als Input für die Entwicklung von Fahrfunktionen

3.5 Veröffentlichungen

3.5.1 Erfolgte Veröffentlichungen

Eine umfangreiche Liste von Veröffentlichungen von Ergebnissen und deren Nutzen, sowie Präsentationen und Pressematerial ist hier zu finden:

<https://www.kiwissen.de/publications> und
<https://www.kiwissen.de/news>

Dort sind auch folgende Veröffentlichungen zu finden:

- Dominik Grundt, Sorin Liviu Jurj: Verification of Sigmoidal Artificial Neural Networks using iSAT. Präsentiert auf dem 7th International Workshop on Symbolic-Numeric Methods for Reasoning about CPS and IoT.
- Gesina Schwalbe, Bettina Finzel: XAI Method Properties: A (Meta-)study. In: Data Mining and Knowledge Discovery, Special Issue on Explainable and Interpretable Machine Learning and Data Mining.
- Sorin Liviu Jurj, Dominik Grundt, Tino Werner, Philipp Borchers, Eike Möhlmann: Increasing the Safety of Adaptive Cruise Control using Physics-guided Reinforcement Learning. In:

Energies, Special Issue "Advances in Automated Driving Systems".
<https://doi.org/10.3390/en14227572>

- Gesina Schwalbe: Concept Embedding Analysis: A Review. In: Artificial Intelligence Review, März 2022.
- Daniel Bogdoll, Moritz Nekolla, Tim Joseph, J. Marius Zöllner: Quantification of Actual Road User Behavior on the Basis of Given Traffic Rules. In: 33rd IEEE Intelligent Vehicles Symposium, 05.-09.06.2022.
- Jörg Reichardt: Trajectories as Markov States for Long Term Traffic Scene Prediction. UniDAS FAS Workshop, 09.05.2022.
- Tianming Qiu: SViT: Hybrid Vision Transformer Models with Scattering Transform. In: 32nd IEEE International Workshop on Machine Learning for Signal Processing (MLSP 2022), Xi'an, China, 22.08.2022.
- Sorin Liviu Jurj, Tino Werner, Dominik Grundt, Eike Möhlmann: Towards Safe and Sustainable Autonomous Vehicles using Environmentally-Friendly Criticality Metrics. Sustainability, Special Issue "Research on Sustainable Transportation and Urban Traffic", 07.06.2022
- Dominik Grundt, Eike Möhlmann: Towards Runtime Monitoring of Complex System Requirements for Autonomous Driving Functions. In: Formal Methods for Autonomous Systems 2022.
- Abdul Hannan Khan, Mohsin Munir, Ludger van Elst: F2DNet: Fast Focal Detection Network for Pedestrian Detection. In: 26th International Conference on Pattern Recognition, Montréal, 22.-25.08.2022.
- Alexander Steen, David Fuenmayor, Tobias Gleißner, Geoff Sutcliffe, Christoph Benzmlüller: Automated Reasoning in Non-classical Logics in the TPTP World, Haifa, Israel, 11.08.2022
- Kumar Manas, Stefan Zwicklbauer, Adrian Paschke: Robust Traffic Rules and Knowledge Representation for Conflict Resolution in Autonomous Driving, Virtual, 26.09.22
- Abdul Hannan Khan: Localized Semantic Feature Mixers for Efficient Pedestrian Detection in Autonomous Driving, The IEEE/CVF Conference on Computer Vision and Pattern Recognition 2023, Vancouver Canada, 18.-22.06.2023
- Himanshu Agarwal, Christian Brunner, Tobias Latka, Stefan Pilar von Pilchau: A Causal Model for Physics-Conform Vehicle Trajectories, IEEE ITSC-2023, 24.-28.09.2023
- Adrien Wantiez, Tianming Qiu, Stefan Matthes, Hao Shen: Scene Understanding for Autonomous Driving Using Visual Question Answering, Gold coast, Queensland, Australia, 18 Jun 2023
- Yue Yao, Joerg Reichardt, Daniel Goehring: An Empirical Bayes Analysis of Object Trajectory Representation Models, ITSC 2023 Bilbao, Spain, 24.-28.09.2023
- Joshua Niemeijer Sudhanshu Mittal, Thomas Brox: Synthetic Dataset Acquisition for a Specific Target Domain, ICCV BRAVO Workshop, Paris, France, 3.10.2023
- Kumar Manas, Adrian Paschke: Legal Compliance Checking of Autonomous Driving with Formalized Traffic Rule Exceptions, ICLP 2023, London, UK, 09.07.2023
- Ya Wang, Adrian Paschke: Extracting Interpretable Hierarchical Rules from Deep Neural Networks' Latent Space, The 7th International Joint Conference on Rules and Reasoning, Oslo, Norway, 18.09.2023

- Julian Wörmann, Daniel Bogdoll, Christian Brunner, Etienne Bührle, Han Chen, Evaristus Fuh Chuo, Kostadin Cvejovski, Ludger van Elst, Philip Gottschall, Stefan Griesche, Christian Hellert, et al.: Knowledge Augmented Machine Learning with Applications in Autonomous Driving: A Survey, 15.11.2023
- Joshua Niemeijer, Jan-Aike Termöhlen, Manuel Schwonberg, Nico M. Schmid, Tim Fingscheidt: Generalization by Adaptation: Diffusion-Based Domain Extension for Domain-Generalized Semantic Segmentation, Waikoloa, Hawaii, USA, 04.-08.01.2024
- Abhishek Vivekanandan, Niels Maier, J. Marius Zöllner: Plausibility Verification For 3D Object Detectors Using Energy-Based Optimization, European Conference on Computer Vision, 15.02.2023
- Georgii Mikriukov, Gesina Schwalbe, Christian Hellert, Korinna Bade: Evaluating the Stability of Semantic Concept Representations in CNNs for Robust Explainability, XAI 2023 Lisboa, Portugal, 26-28.07.2023
- Georgii Mikriukov, Gesina Schwalbe, Christian Hellert, Korinna Bade: Revealing Similar Semantics Inside CNNs: An Interpretable Concept-based Comparison of Feature Spaces, AIMLAI 2023 (ECML 2023) Torino, Italy, 18-22.09.2023
- Christian Schlauch, Christian Wirth: Informed Priors for Knowledge Integration in Trajectory Prediction, ECML-PKDD 2023 in Turin, Italy, 18-22.09.2023
- Mert Keser, Gesina Schwalbe: Interpretable Model-Agnostic Plausibility Verification for 2D Object Detectors Using Domain-Invariant Concept Bottleneck Models, CVPR 2023 SAIAD Workshop, Vancouver, Canada, 19.07.2023
- Kumar Manas, Adrian Paschke: Semantic Role Assisted Natural Language Rule Formalization for Intelligent Vehicle, 18.09.2023
- Daniel Bogdoll, Jing Qin, Moritz Nekolla, Ahmed Abouelazm, Tim Joseph, J. Marius Zöllner: Informed Reinforcement Learning for Situation-Aware Traffic Rule Exceptions, ICRA in Yokohama, Japan, 13.05.2024
- Mohamed-Khalil Bouzidi, Yue Yao, Joerg Reichardt: Learning-Aided Warmstart of Model Predictive Control in Uncertain Fast-Changing Traffic, Yokohama, Japan, 05.2024

Bei folgender Veröffentlichung während der Projektlaufzeit hat Valeo direkt mitgewirkt:

- Julian Wörmann, Daniel Bogdoll, Christian Brunner, Etienne Bührle, Han Chen, Evaristus Fuh Chuo, Kostadin Cvejovski, Ludger van Elst, Philip Gottschall, Stefan Griesche, Christian Hellert, et al.: Knowledge Augmented Machine Learning with Applications in Autonomous Driving: A Survey, 15.11.2023
- Dominik Grundt, Philipp Borchers, Laura von Rueden, Hendrik Königshof, Stefan Griesche, Aiman Hsino, Daniel Bär, Etienne Bührle, Han Chen, Tobias Gleißner, Philip Gottschall et al.: Conjoint Whitepaper Deliverable D1 & D4, 1.1.2022
- Daniel Bogdoll, Antoine Demailleur, Ludger van Elst, Tobias Gleißner, Tim Joseph, Johann Kelsch, Tobias Latka, Mohsin Munir, Syed Tahseen Raza Rizvi, Jörg Reichardt, Matthias Reuse, et al.: Learning Techniques for Integrating Formalized Knowledge and Network Knowledge for Training Reduction and Performance Improvement, 3.8.2022

3.5.2 Geplante Veröffentlichungen

Weitere Veröffentlichungen nach Projektende sind nicht geplant.

4 Literaturverzeichnis

- [1] Bundesministerium für Wirtschaft und Energie, „Fachprogramm Neue Fahrzeug- und Systemtechnologien,“ Mai 2015.
- [2] Bundesregierung, „Strategie Künstliche Intelligenz der Bundesregierung,“ 11 2018. [Online]. Available: https://www.ki-strategie-deutschland.de/home.html?file=files/downloads/Nationale_KI-Strategie.pdf. [Zugriff am 05 12 2018].
- [3] Bundesministerium der Finanzen, „Eckpunkte des Konjunkturpakets: Corona-Folgen bekämpfen, Wohlstand sichern, Zukunftsfähigkeit stärken,“ 2020.
- [4] S.-M. Moosavi-Dezfooli, A. Fawzi, O. Fawzi und P. Frossard, „Universal adversarial perturbations,“ *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 86-94, 2016.
- [5] Frost & Sullivan, „Global Autonomous Driving Market Outlook,“ 2017.
- [6] Bundesministerium für Wirtschaft und Energie, „Hochautomatisiertes Fahren auf Autobahnen – Industriepolitische Schlussfolgerungen, Studie des Fraunhofer IAO im Auftrag des BMVI,“ Dienstleistungsprojekt 15/14, November 2015.
- [7] IHS Technology, „AI systems for autonomous driving on the rise: report,“ 2016. [Online]. Available: <http://newsbytes.ph/2016/06/15/ai-systems-for-autonomous-driving-on-the-rise-report/>. [Zugriff am 24 April 2018].
- [8] McKinsey&Company, „Artificial intelligence - Automotive's new value creating engine,“ Januar 2018. [Online]. Available: <https://www.mckinsey.com/~media/McKinsey/Industries/Automotive%20and%20Assembly/Our%20Insights/Artificial%20intelligence%20as%20auto%20companies%20new%20engine%20of%20value/Artificial-intelligence-Automotives-new-value-creating-engine.ashx>. [Zugriff am 24 April 2018].
- [9] Stanford AI Lab, „artificial intelligence index – 2017 Annual Report November 2017,“ November 2017. [Online]. Available: <http://cdn.aiindex.org/2017-report.pdf>. [Zugriff am 26 April 2018].
- [10] A. Krizhevsky, I. Sutskever und G. Hinton, „Imagenet classification with deep convolutional neural networks,“ *Advances in neural information processing systems*, 2012.
- [11] H. Alex, „Die Dewey-Dezimalklassifikation (DDC),“ in *Klassifikationen in Bibliotheken*, De Gruyter Saur, 2018, pp. 65 - 110.
- [12] M. Lutter, C. Ritter und J. Peters, „Deep lagrangian networks: Using physics as model prior for deep learning,“ *arxiv:1907, 04490*, 2019.

- [13] S. Balogh und R. Chamraz, „Two approaches to the adaptive cruise control (ACC) design,“ *Cybernetics Informatics (K&I)*, pp. 1-6, 2018.
- [14] G. Towell und J. Shavlik, „Knowledge-based artificial neural networks,“ *Artificial Intelligence*, vol. 70, no. 1-2 1994.
- [15] B. Yet, Z. Perkins, N. Fenton, N. Tai und W. Marsh, „Not just data: A methos of improving prediction with knowledge,“ *J. Biomedical Informatics*, vol. 48, 2014.
- [16] B. Schölkopf, P. Simard, A. Smola und V. Vapnik, „Prior knowledge in support vector kernels,“ *Adv. in Neural Information Processing Systems (NIPS)*, 1998.
- [17] P. W. Battaglia, J. B. Hamrick, V. Bapst, A. Sanchez-Gonzalez, V. Zambaldi, M. Malinowski und A. Tacchetti, „Relational inductive biases, deep learning, and graph networks,“ *CoRR*, 6 2018.
- [18] Y. Fang, K. Kuan, J. Lin, C. Tan und V. Chandrasekhar, „Object detection meets knowledge graphs,“ 2017.
- [19] A. Shrivastava, T. Pfister, O. Tuzel, J. Susskind, W. Wang und R. Webb, „Learning from simulated and supervised images through adversarial training,“ *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2017.
- [20] W. Damm, S. Kemper, E. Möhlmann, T. Peikenkamp und A. Rakow, „Traffic Sequence Charts - From Visualization to Semantics,“ SFB/TR 14 AVACS, 2017.
- [21] W. Damm, E. Möhlmann, T. Peikenkamp und A. Rakow, „A Formal Semantics for Traffic Sequence Charts,“ *Principles of Modeling - Essays Dedicated to Edward A. Lee on the Occasion of His 60th Birthday*, pp. 182-205, 2018.
- [22] W. Damm, S. Kemper, E. Möhlmann, T. Peikenkamp und A. Rakow, „Using Traffic Sequence Charts for the Development of HAVs,“ *European Congress on Embedded Real Time Software and Systems 2018*, 2018.
- [23] A. Zisserman und R. I. Hartley, *Multiple View Geometry in Computer Vision*, Cambridge University Press, 2012.
- [24] J. Gamba, *Radar Signal Processing for Autonomous Driving*, Springer, 2019.
- [25] Volvo Cars, [Online]. Available: <https://www.volvocars.com/en-th/support/manuals/xc60/2021/driver-support/pilot-assist/limitations-of-pilot-assist>.
- [26] J. Ziegler, P. Bender, M. Schreiber, H. Lategahn, T. Strauss, C. Stiller und T. Dang, „Making Bertha Drive - An Autonomous Journey on a Historic Route,“ *IEEE Intelligent Transportation Systems Magazine*, 6 (2), pp. 8-20, 2014.

- [27] D. C. Psychogios und L. H. Ungar, „A hybrid neural network-first principles approach to process modeling,“ *AIChE Journal*, pp. 1499-1511, 1992.
- [28] M. L. Thompson und M. A. Kramer, „Modeling chemical processes using prior knowledge and neural networks,“ *AIChE Journal*, pp. 1328-1340, 1994.
- [29] B.-G. Hu, H.-B. Qu, Y. Wang und S.-H. Yang, „A generalized-constraint neural network model: Associating partially known relationships for nonlinear regressions,“ *Information Sciences*, pp. 1929-1943, 2009.
- [30] R. Stewart und S. Ermon, „Label-Free Supervision of Neural Networks with Physics and Domain Knowledge,“ *CoRR*, 2016.
- [31] A. Kosciński und J. E. Souza de Cursi, „Physically Constrained Neural Networks and Regularization of Inverse Problems,“ 2005.
- [32] S. N. Ravi, T. Dinh, V. S. R. Lokhande und V. Singh, „Constrained Deep Learning using Conditional Gradient and Applications in Computer Vision,“ *CoRR*, 2018.
- [33] X. Jia, J. Willard, A. Karpatne, J. Read, J. Zward, M. Steinbach und V. Kumar, „Physics Guided RNNs for Modeling Dynamical Systems: A Case Study in Simulating Lake Temperature Profiles,“ 10 2018.
- [34] M. Raissi, P. Perdikaris und G. Karniadakis, „Physics Informed Deep Learning (Part I): Data-driven Solutions of Nonlinear Partial Differential Equations,“ 11 2017.
- [35] K. E. Kalman, „A new approach to linear filtering and prediction problems,“ *Journal of Basic Engineering*, Bd. 82, Nr. 1, pp. 35-45, 1960.
- [36] F. Auger, M. Hilariet, J. M. Guerrero, E. Monmasson, T. Orlowska-Kowalska und S. Katsura, „Industrial Applications of the Kalman Filter: A Review,“ *IEEE Transactions on Industrial Electronics*, Bd. 60, Nr. 12, pp. 5458-5471, 2013.
- [37] S. Särkkä, *Bayesian filtering and smoothing*, Cambridge: Cambridge University Press, 2013.
- [38] M. Karl, M. Soelch, J. Bayer und P. van der Smagt, „Deep Variational Bayes Filters: Unsupervised Learning of State Space Models from Raw Data,“ in *International Conference on Learning Representations*, Toulon, 2017.
- [39] H. Coskun, F. Achilles, R. DiPietro, N. Navab und F. Tombari, „Long-Short-Term Memory Kalman Filters: Recurrent Neural Networks for Pose Regularization,“ in *ICCV*, 2017.
- [40] D. P. Kingma und M. Welling, „Auto-Encoding Variational Bayes,“ in *2nd International Conference on Learning Representations*, Banff, Canada, 2014.

- [41] J. Chung, K. Kastner, L. Dinh, K. Goel, A. Courville und Y. Bengio, „A Recurrent Latent Variable Model for Sequential Data,“ in *Advances in Neural Information Processing Systems 28*, 2015.
- [42] J. Bayer und C. Osendorfer, „Learning Stochastic Recurrent Networks,“ 2014.
- [43] M. Watter, J. Springenberg und J. Boedecker, „Embed to control: A locally linear latent dynamics model for control from raw images,“ in *Advances in Neural Information Processing Systems*, 2015.
- [44] M. Fraccaro, S. Sönderby, U. Paquet und O. Winther, „Sequential Neural Models with Stochastic Layers,“ in *Advances in Neural Information Processing Systems 29*, 2016.
- [45] J. Pearl, Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference, Morgan Kaufman, 1988.
- [46] J. Pearl, Causality, 2nd Edition, Cambridge University Press, 2009.
- [47] D. Koller und N. Friedman, Probabilistic Graphical Models: Principles and Techniques, MIT press, 2009.
- [48] T. Kipf und M. Welling, „Semi-supervised classification with Graph Convolutional Networks,“ in *International Conference of Learning Representations, ICLR*, 2017.
- [49] M. Bronstein, J. Bruna, Y. LeCun, A. Szlam und P. Vandergheynst, „Geometric deep learning: going beyond Euclidean data,“ *IEEE Signal Processing Magazine*, 2017.
- [50] A. d'Avila Garcez, D. Gabbay und K. Broda, Neural-Symbolic Learning System: Foundations and Applications, Springer, 2002.
- [51] A. S. d'Avila Garcez, L. C. Lamb und D. M. Gabbay, „Neural-Symbolic Cognitive Reasoning,“ *Cognitive Technologies*, 2009.
- [52] B. Hammer und P. Hitzler, Perspectives of Neural-Symbolic Integration, Springer, 2007.
- [53] L. Valiant, „Knowledge infusion,“ in *AAAI*, 2006.
- [54] L. d. Penning, A. d. Garcez, L. Lamb und J. Meyer, „A neural-symbolic cognitive agent for online learning and reasoning,“ in *IJCAI*, 2011.
- [55] Y. Bengio, A. Courville und P. Vincent, „Representation Learning: A Review and New Perspectives,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, August 2013.
- [56] X. Chen, Y. Duan, R. Houthoofd, J. Schulman, I. Sutskever und P. Abbeel, „InfoGAN: Interpretable representation learning by information maximizing

generative adversarial nets," in *Advances in neural information processing systems*, 2016, pp. 2172-2180.

- [57] L. H. Gilpin, D. Bau, B. Z. Yuan, A. Bajwa, M. Specter und L. Kagal, „Explaining Explanations: An Overview of Interpretability of Machine Learning,“ in *5th IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, 2018.
- [58] D. Keim, G. Andrien, K.-D. Fekete, C. Görg, J. Kohlhammer und G. Melançon, „Visual Analytics: Definition, Process, and Challenges,“ in *Information Visualization , Lecture Notes in Computer Science*, 2008, pp. 154-175.
- [59] P. J. Kindermans, K. T. Schütt, M. Alber, K. R. Müller, D. Erhan, B. Kim und S. Dähne, „Learning how to explain neural networks: Patternnet and patternattribution.,“ *arXiv preprint*, p. arXiv:1705.05598, 2017.
- [60] L. van der Maaten und G. Hinton, „Visualizing data using t-SNE.,“ *Journal of machine learning research*, 2008.
- [61] G. Ras, M. van Gerven und P. Haselager, „Explanation methods in deep learning: Users, values, concerns and challenges,“ in *Explainable and Interpretable Models in Computer Vision and Machine Learning*, Springer, 2018, pp. 19-36.
- [62] S. N. Tran und A. d'Avila Garcez, „Deep logic networks: Inserting and extracting knowledge from deep belief networks,“ *IEEE T. Neur. Net. Learning Syst.*, p. 246–258, 2018.
- [63] S. Antol, A. Agrawal, J. Lu, M. Mitchell, D. Batra, C. L. Zitnick und D. Parikh, „VQA: Visual Question Answering,“ *IEEE International Conference on Computer Vision (ICCV)*, 2015.
- [64] W. Wang, Y. Huang, W. Yizhou und L. Wang, „Generalized Autoencoder: A Neural Network Framework for Dimensionality Reduction,“ *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, pp. 496-503, 2014.
- [65] I. Goodfellow, Y. Bengio und A. Courville, *Deep Learning*, MIT Press, 2016.
- [66] P. Vincent, H. Larochelle, Y. Bengio und P.-A. Manzagol, „Extracting and Composing Robust Features with Denoising Autoencoders,“ *Proceedings of the 25th International Conference on Machine Learning*, 2008.
- [67] S. Rifai, P. Vincent, X. Muller, X. Glorot und Y. Bengio, „Contractive Auto-Encoders: Explicit Invariance During Feature Extraction,“ *Proceedings of the 28th International Conference on Machine Learning*, 2011.
- [68] S. Huang und H. Xing, „Extract intelligible and concise fuzzy rules from neural networks,“ *Fuzzy Sets and Systems* , Bd. 132, Nr. 2, pp. 233-243, 2002.

- [69] J. Huysmans, B. Baesens und J. Vanthienen, „(2006). Using rule extraction to improve the comprehensibility of predictive models,“ *SSRN Electronic Journal*, 2016.
- [70] Kumar, Ray und Kumar, „Implementation and Application of Fuzzy Logic in Automobiles for The Purpose of Control, Navigation and Tracking of Non Automated and Automated Guided Vehicles,“ *International Journal of Science Technology & Engineering*, 2017.
- [71] J. Tang, F. Liu, W. Zhang, R. Ke und Y. Zou, „Lane-changes prediction based on adaptive fuzzy neural network,“ *Expert Systems with Applications*, Bd. 91, pp. 452-463, 2018.
- [72] M. Richardson und P. Domingos, „Markov Logic Networks.,“ *Machine Learning*, 62 (1-2), p. 107–136, 2006.
- [73] C. Stiller, S. Kammel, I. Lulcheva und J. Ziegler, „Probabilistic methods for environment perception of cognitive automobiles,“ *at-Automatisierungstechnik* 56 (11), pp. 563-574, 2008.
- [74] M. Huegle, G. Kalweit, B. Mirchevska, M. Werling und J. Boedecker, „arXiv,“ 25 Juli 2019. [Online]. Available: <https://arxiv.org/abs/1907.10994>. [Zugriff am 20 August 2019].
- [75] R. Sun, „Knowledge extraction from reinforcement learning,“ *IJCNN'99. International Joint Conference on Neural Networks. Proceedings (Cat. No.99CH36339)*, pp. 2554-2559, 1999.
- [76] D. Koller and N. Friedman, *Probabilistic Graphical Models: Principles and Technique*, Cambridge, Massachusetts, London, England: The MIT Press, 2009.
- [77] V. Leonhardt, T. Pech and G. Wanielik, „Fusion of Driver Behaviour Analysis and Situation Assessment for Probabilistic Manoeuvre Prediction,“ in *UR:BAN Human Factors in Traffic*, Wiesbade, Springer Fachmedien, 2018, pp. 223-244.
- [78] A. Koenig, T. Rehder und S. Hohmann, „Exact Inference and Learning in Hybrid Bayesian Networks for Lane Change Intention Classification,“ *Proceedings of the 2017 IEEE Intelligent Vehicles Symposium (IV)*, pp. 1535-1540, 2017.
- [79] J. Schulz, C. Hubmann, J. Löchner und B. Darius, „Multiple Model Unscented Kalman Filtering in Dynamic Bayesian Networks for Intention Estimation and Trajectory Prediction,“ *10.1109/ITSC.2018.8569932*, 2018.
- [80] S. Nowozin und C. H. Lampert, *Structured Learning and Prediction in Computer Vision (Foundations and Trends in Computer Graphics and Vision)*, 2011.

- [81] R. Houthoofd, C. De Boom, S. Verstichel, F. Ongenae und F. De Turck, „Structured output prediction for semantic perception in autonomous vehicles,“ in *AAAI*, 2016.
- [82] L.-C. Chen, A. G. Schwing, A. L. Yuille und R. Urtasun, „Learning Deep Structured Models,“ in *ICML*, 2015.
- [83] T. Young, D. Hazarika, S. Poria und E. Cambria, „Recent Trends in Deep Learning Based Natural Language Processing,“ 25 11 2018. [Online]. Available: <https://arxiv.org/pdf/1708.02709.pdf>. [Zugriff am 20 08 2019].
- [84] K. Jezek und J. Steinberger, „Automatic Text Summarization (The state of the art 2007 and new challenges),“ 2007.
- [85] R. Nallapati, B. Zhou, C. N. dos Santos, C. Gulcehre und B. Xiang, „Abstractive Text Summarization Using Sequence-to-Sequence RNNs and Beyond,“ 19 02 2016. [Online]. Available: <https://arxiv.org/abs/1602.06023>. [Zugriff am 20 08 2019].
- [86] L. Liu, Y. Lu, M. Yang, Q. Qu, J. Zhu und H. Li, „Generative Adversarial Network for Abstractive Text Summarization,“ 16 11 2017. [Online]. Available: <https://arxiv.org/abs/1711.09357>. [Zugriff am 20 08 2019].
- [87] R. A. Jacobs, M. I. Jordan, S. J. Nowlan und G. E. Hinton, „Adaptive Mixture of Local Experts,“ *Neural Computation*, pp. 79-87, 1991.
- [88] A. Verma, R. Hebbalaguppe, L. Vig, S. Kumar und E. Hassan, „Pedestrian Detection via Mixture of CNN Experts and Thresholded Aggregated Channel Features,“ *IEEE International Conference on Computer Vision Workshop (ICCVW)*, pp. 555-563, 2015.
- [89] H. Fu, M. Gong, C. Wang und D. Tao, „MoE-SPNet: A Mixture-of-Experts Scene Parsing Network,“ *arXiv:1806.07049 [cs]*, 2018.
- [90] O. Mees, A. Eitel und W. Burgard, „Choosing Smartly: Adaptive Multimodal Fusion for Object Detection in Changing Environments,“ *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 151-156, 2016.
- [91] C. Blundell, J. Cornebise, K. Kavukcuoglu und D. Wierstra, „Weight Uncertainty in Neural Networks,“ *arXiv:1505.05424 [cs, stat]*, 2015.
- [92] D. Zhang, L. Lu, L. Guo und G. Karniadakis, „Quantifying total uncertainty in physics-informed neural networks for solving forward and inverse stochastic problems,“ 2018.
- [93] S. A. A. Kohl, B. Romera-Paredes, C. Meyer, J. De Fauw, J. R. Ledsam, K. H. Maier-Hein, S. M. A. Eslami, D. J. Rezende und O. Ronneberger, „A Probabilistic

U-Net for Segmentation of Ambiguous Images," *32nd Conference on Neural Information Processing Systems (NeurIPS)*, 2018.

- [94] X.-W. Chen und X. Lin, „Big Data Deep Learning: Challenges and Perspectives," *IEEE Access*, Nr. 2, pp. 514-525, 2014.
- [95] W. Ma, M. Papadakis, A. Tsakmalis, M. Cordy und Y. Le Traon, „Test Selection for Deep Learning Systems," *arXiv*, p. 1904.13195, 2019.
- [96] X. Huang und J. R. Jensen, „A Machine-Learning Approach to Automated Knowledge-Base Building for Remote Sensing Image Analysis with GIS Data," *Photogrammetric Engineering & Remote Sensing*, Bd. 63, pp. 1185-1194, 1997.
- [97] M. Waldmann, *The Oxford Handbook of Causal Reasoning*, Oxford University Press, 2017.
- [98] L. v. Rueden, S. Mayer, J. Garcke, C. Bauckhage und J. Schuecker, „Informed Machine Learning - Towards a Taxonomy of Explicit Integration of Knowledge into Machine Learning," *arXiv:1903.12394 [stat.ML]*, 2018.
- [99] J.-X. Wang, J.-L. Wu und H. Xiao, „Physics-informed machine learning approach for reconstructing Reynolds stress modeling discrepancies based on DNS data," in *Phys. Rev. Fluids*, 2017, p. 034603.
- [100] F. d. A. Belbute-Peres, K. Smith, K. Allen, J. Tenenbaum und J. Z. Kolter, „End-to-End Differentiable Physics for Learning and Control," *Advances in Neural Information Processing Systems 31*, 2018.
- [101] J. Lehmann, R. Isele, M. Jakob, A. Jentzsch, D. Kontokostas, P. N. Mendes, S. Hellmann, M. Morsey, P. v. Kleef, S. Auer und C. Bizer, „DBpedia - a large-scale, multilingual knowledge base extracted from Wikipedia," in *Semantic Web*, 2015, pp. 167-195.
- [102] J. Xu, Z. Zhang, T. Friedman, Y. Liang und G. van den Broeck, „A Semantic Loss Function for Deep Learning with Symbolic," in *Proceedings of the 35th International Conference on Machine Learning*, 2018.
- [103] A. Ratner, C. D. Sa, S. Wu, D. Selsam und C. Ré, „Data Programming: Creating Large Training Sets, Quickly," *Advances in Neural Information Processing Systems*, 2016.
- [104] M.-W. Chang, L. Ratinov und D. Roth, „Guiding Semi-Supervision with Constraint-Driven Learning," in *Annual Meeting of the Association of Computational Linguistics*, 2007.
- [105] R. Swischuk, L. Mainini, B. Peherstorfer und K. Willcox, „Projection-based model reduction: Formulations for physics-based machine learning," 2018.

- [106] E. d. Bézenac, A. Pajot und P. Gallinari, „Deep Learning for Physical Processes: Incorporating prior Scientific Knowledge,“ 2018.
- [107] N. Fulton und A. Platzer, „Safe AI for CPS (Invited Paper)“.
- [108] M. Everingham, L. Van Gool, C. K. I. Williams und J. W. Zisserman, „The PASCAL Visual Object Classes (VOC) Challenge,“ *International Journal of Computer Vision*, pp. 303-338, Juni 2010.
- [109] H. Caesar, V. Bankiti, A. H. Lang, S. Vora, V. E. Liong, Q. Xu, A. Krishnan, Y. Pan, G. Baldan und O. Beijbom, „nuScenes: A multimodal dataset for autonomous driving,“ *arXiv preprint: <https://arxiv.org/abs/1903.11027>*, 2019.
- [110] P. Sun, H. Kretzschmar, X. Dotiwalla, A. Chouard, V. Patnaik, P. Tsui, J. Guo, Y. Zhou, Y. Chai, B. Caine, V. Vasudevan, W. Han, J. Ngiam, H. Zhao, A. Timofeev und S. Ettinger, „Scalability in Perception for Autonomous Driving: Waymo Open Dataset,“ *arXiv preprint: <https://arxiv.org/abs/1912.04838>*, 2019.
- [111] J. Phillion, A. Kar und S. Fidler, „Learning to Evaluate Perception Models Using Planner-Centric Metrics,“ *arXiv preprint: <https://arxiv.org/abs/2004.08745>*, 2020.
- [112] M. Dupuis, M. Strobl und H. Grezlikowski, „OpenDRIVE 2010 and Beyond–Status and Future of the de facto Standard for the Description of Road Networks,“ in *Driving Simulation Conference Europe*, 2010.
- [113] „OpenSCENARIO,“ [Online]. Available: <http://www.openscenario.org/>. [Zugriff am 2019].
- [114] DLR, „Eclipse SUMO – Simulation of Urban MObility,“ [Online]. Available: https://www.dlr.de/ts/de/desktopdefault.aspx/tabid-9883/16931_read-41000/. [Zugriff am August 2019].
- [115] S. Curtis, A. Best und D. Manocha, „Menge: A modular framework for simulating crowd movement,“ *Collective Dynamics*, 2016.
- [116] „ROS: Robot Operating System,“ [Online]. Available: <http://www.ros.org/>. [Zugriff am August 2019].
- [117] „PEGASUS Projekt,“ [Online]. Available: <https://www.pegasusprojekt.de/de/>. [Zugriff am August 2019].
- [118] Catapult, „MUSICC - Multi User Scenario Catalogue for Connected Autonomous Vehicles,“ [Online]. Available: <https://ts.catapult.org.uk/innovation-centre/cav/cav-projects-at-the-tsc/musicc/>. [Zugriff am August 2019].
- [119] CARLA, „CARLA ScenarioRunner,“ [Online]. Available: https://github.com/carla-simulator/scenario_runner. [Zugriff am August 2019].

- [120] S. Ioffe und C. Szegedy, „Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,“ *CoRR*, 2015.
- [121] K. He, X. Zhang, S. Ren und J. Sun, „Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,“ *CoRR*, 2015.
- [122] S. Russel und P. Norvig, *Artificial Intelligence: A Modern Approach*, Pearson Education, 2010.
- [123] K. Simonyan und A. Zisserman, „Very Deep Convolutional Networks for Large-Scale Image Recognition,“ *CoRR*, 2014.
- [124] K. Eykholt, I. Evtimov, E. Fernandes, B. Li, A. Rahmati, C. Xiao, A. Prakash, T. Kohno und D. Song, „Robust physical-world attacks on deep learning visual classification,“ in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018.
- [125] S. Sankaranarayanan, Y. Balaji, A. Jain, S. N. Lim und R. Chellappa, „Learning from Synthetic Data: Addressing Domain Shift for Semantic Segmentation,“ 01 04 2018. [Online]. Available: <https://arxiv.org/abs/1711.06969>. [Zugriff am 28 03 2019].
- [126] J. Fürnkranz, D. Gamberger und N. Lavrač, *Foundations of Rule Learning*, Berlin: Springer-Verlag, 2014.
- [127] G. Montavon, W. Samek und K.-R. Müller, „Methods for interpreting and understanding deep neural networks,“ *Digital Signal Processing* 73, pp. 1-15, 2018.
- [128] D. A. Pomerleau, „Alvin: An autonomous land vehicle,“ in *Advances in Neural Information*, 1989.
- [129] M. Bojarsk, D. Del Testa, B. F. Dworakowski, B. Flepp, M. Monfort, U. Muller und J. Zhang, „End to end learning for self driving cars,“ *arXiv preprint arXiv:1604.07316*, 2016.
- [130] M. Bojarsk, P. Yeres, A. Choromanska, K. Choromanski, B. Firner, L. Jackel und U. Muller, „Explaining how a deep neural network trained with end-to-end learning steers a car,“ *arXiv preprint arXiv:1704.07911*, 2017.
- [131] Y. Pan, C.-A. Chen, K. Saigol, K. Lee, X. Yan, E. A. Theodorou und B. Boots, „Agile Autonomous Driving using End-to-End Deep Imitation Learning,“ *arXiv preprint arxiv.org/abs/1709.07174*, 2017.
- [132] A. Kendal, J. Hawke, D. Janz, P. Mazur, D. Reda, J.-M. Allen, V.-D. Lam, A. Bewley und A. Shah, „Learning to Drive in a Day,“ <https://arxiv.org/abs/1807.00412>.

- [133] M. Bansal, A. Krizhevsky und O. A. „ChauffeurNet: Learning to Drive by Imitating the Best and Synthesizing the Worst,“ *arxiv preprint arxiv.org/abs/1812.03039*, 2018.
- [134] C. Sun, A. Shrivastata, S. Singh und A. Gupta, „Revisiting Unreasonable Effectiveness of Data in Deep Learning Era,“ in *ICCV*, 2017.
- [135] G. Marcus, „Deep Learning: A Critical Appraisal,“ *arxiv preprint arxiv.org/abs/1801.00631*, 2018.
- [136] B. M. Lake, T. D. Ullmann, J. B. Tenenbau und S. J. Gershman, „Building Machines That Learn and Think Like People,“ *Behavioral and Brain Sciences*, Bd. 40, p. e253, 2017.
- [137] T. R. Besold, A. d'Avila Garcez, S. Bader, H. Bowman, P. Domingos, P. Hitzler, K.-U. Kuehnberger, L. C. Lamb, D. Lowd, P. Machado Vieira Lima, L. de Penning, G. Pinkas, H. Poon und G. Zaverucha, „Neural-Symbolic Learning and Reasoning: A Survey and Interpretation,“ 11 10 2017. [Online]. Available: <https://arxiv.org/abs/1711.03902>. [Zugriff am 25 03 2019].
- [138] K. Sethi, D. Mishra und B. Mishra, „Extended taxonomy of rule extraction techniques and assessment of kdruleex,“ *International Journal of Computer Applications*, 2012.
- [139] B. Kim, M. Wattenberg, J. Gilmer, C. Cai, J. Wexler und F. Viegas, „Interpretability Beyond Feature Attribution: Quantitative Testing with Concept Activation Vectors (TCAV),“ *International Conference on Machine Learning*, pp. 2673-2682, 2018.
- [140] D. Xu, Y. Shi, I. W. Tsang, Y.-S. Ong, C. Gong und X. Shen, „A Survey on Multi-output Learning,“ 2019.
- [141] D. Roth, „Incidental Supervision: Moving beyond Supervised Learning,“ *AAAI*, 2017.
- [142] Y. Kim, C. Denton, L. Hoang und A. M. Rush, „Structured Attention Networks,“ *ICLR*, 2017.
- [143] A. Karpatne, W. Watkins, J. Read und V. Kumar, „Physics-guided Neural Networks (PGNN): An Application in Lake Temperature Modeling,“ 2018.
- [144] B. Becker, A. Podelski, W. Damm, M. Fränzle, E.-R. Olderog und R. Wilhelm, „SFB/TR 14 AVACS - Automatic Verification and Analysis of Complex Systems,“ *it - Information Technology* 49(2), pp. 118-126, 2007.
- [145] A. Dosovitskiy, G. Ros, F. Codevilla, A. Lopez und V. Koltun, „CARLA: An Open Urban Driving Simulator,“ in *Proceedings of the 1st Annual Conference on Robot Learning*, 2017.

- [146] A. Geiger, P. Lenz, C. Stiller und R. Urtasun, „Vision meets Robotics: The KITTI Dataset,“ *International Journal of Robotics Research (IJRR)*, 2013.
- [147] M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Benenson, U. Franke, S. Roth und B. Schiele, „The Cityscapes Dataset for Semantic Urban Scene Understanding,“ *Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [148] F. Yu, H. Chen, X. Wang, W. Xian, Y. Chen, F. Lui, V. Madhavan und T. Darrell, „BDD100K: A Diverse Driving Dataset for Heterogeneous Multi-task Learning,“ 2018.
- [149] R. Kesten, M. Usman, J. Houston, T. Pandya, K. Nadhamuni, A. Ferreira, M. Yuan, B. Low, A. Jain, P. Ondruska, S. Omari, S. Shah, A. Kulkarni, A. Kazakova, C. Tao, L. Platinsky, W. Jiang und V. Shet, „Lyft Level 5 AV Dataset 2019,“ 2019.
- [150] W. Zhan, L. Sun, D. Wang, S. Haojie, A. Clausse, M. Naumann, J. Kümmerle, H. Königshof, C. Stiller, A. de La Fortelle und M. Tomizuka, „INTERACTION Dataset: An INTERnational, Adversarial and Cooperative moTION Dataset in Interactive Driving Scenarios with Semantic Maps,“ 2019.
- [151] VDA, „Die VDA-Leitinitiative Autonomes und Vernetztes Fahren - Rollenpapier“, 2018.
- [152] D. Trabold und H. Grosskreutz, „Parallel subgroup discovery on computing clusters - First results,“ *BigData 2013*, pp. 575-579, 2013.
- [153] D. Trabold und T. Horvath, „Mining Strongly Closed Itemsets from Data Streams,“ *Discovery science. 20th International Conference*, pp. 251-266, 2017.
- [154] M. Kamp, L. Adilova, J. Sicking, F. Hüger, P. Schlicht, T. Wirtz und S. Wrobel, „Efficient decentralized deep learning by dynamic model averaging,“ *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, pp. 393-409.
- [155] P. Pékezou Fouopi, „Holistische Modellierung und Interpretation von Szenen und Situationen basierend auf symbolischen, probabilistischen und subsymbolischen Modellen,“ Universität Oldenburg, Oldenburg, 2020.
- [156] VDA, „Positionspapier "Leitinitiative autonomes und vernetztes Fahren",“ Berlin, 2017.
- [157] VDA, „Ein Beitrag der VDA-Leitinitiative autonomes und vernetztes Fahren zur KI-Strategie der Bundesregierung“, unveröffentlicht, 2018.
- [158] cbinsights, „The Race for AI: Google, Intel, Apple in A Rush to Grab Artificial Intelligence Startups,“ 27 Februar 2018. [Online]. Available:

<https://www.cbinsights.com/research/top-acquirers-ai-startups-ma-timeline/>.
[Zugriff am 24 April 2018].

- [159] McKinsey&Company, „Smart Moves required - the road towards artificial intelligence in mobility,“ September 2017. [Online]. Available: <https://www.mckinsey.com/~media/mckinsey/industries/automotive%20and%20assembly/our%20insights/the%20road%20to%20artificial%20intelligence%20in%20mobility%20smart%20moves%20required/smart-moves-required-the-road-towards-artificial-intelligence-in-mobilit>. [Zugriff am 24 April 2018].
- [160] B. Schölkopf, „Kybernetische Revolution,“ [sueddeutsche.de](http://www.sueddeutsche.de), 15 März 2018. [Online]. Available: <http://www.sueddeutsche.de/politik/aussenansicht-kybernetische-revolution-1.3907249>. [Zugriff am 24 April 2018].
- [161] Bundesministerium für Bildung und Forschung, „Verstärkt in Forschung und Innovation investieren,“ 28 Februar 2018. [Online]. Available: <https://www.bmbf.de/de/verstaerkt-in-forschung-und-innovation-investieren-5739.html>. [Zugriff am 24 April 2018].
- [162] Bundesministerium für Wirtschaft und Energie, „Machnig: G7 intensivieren Austausch und Kooperation zu Künstlicher Intelligenz,“ 27 März 2018. [Online]. Available: <https://www.bmwi.de/Redaktion/DE/Pressemitteilungen/2018/20180327-machnig-g7-intensivieren-austausch-und-kooperation-zu-kuenstlicher-intelligenz.html>. [Zugriff am 24 April 2018].
- [163] Bundesregierung, „<https://www.bmwi.de/Redaktion/DE/Publikationen/Technologie/strategie-kuenstliche-intelligenz-der-bundesregierung.html>,“ 15 11 2018. [Online]. Available: https://www.bmwi.de/Redaktion/DE/Publikationen/Technologie/strategie-kuenstliche-intelligenz-der-bundesregierung.pdf?__blob=publicationFile&v=8. [Zugriff am 29 06 2020].
- [164] Bundesministerium für Wirtschaft und Energie, „Künstliche Intelligenz (KI) – Warum Deutschland jetzt durchstarten muss und kann,“ 29 06 2020. [Online]. Available: <https://www.bmwi.de/Redaktion/DE/Artikel/Technologie/kuenstliche-intelligenz-warum-deutschland-jetzt-durchstarten-muss-und-kann.html>.
- [165] J. Hoffman, D. Wang, F. Yu und T. Darrell, „FCNs in the Wild: Pixel-level Adversarial and Constraint-based Adaptation,“ 08 12 2016. [Online]. Available: <https://arxiv.org/abs/1612.02649>. [Zugriff am 28 03 2019].
- [166] Bundesministerium für Bildung und Forschung, „Lernende Systeme müssen der Gesellschaft dienen – nicht umgekehrt,“ 16 März 2018. [Online]. Available: <https://www.bmbf.de/de/lernende-systeme-muessen-der-gesellschaft-dienen---nicht-umgekehrt-5842.html>. [Zugriff am 24 April 2018].

- [167] L. Von Rueden und et al., „Informed Machine Learning - A Taxonomy and Survey of Integrating Knowledge into Learning Systems,“ *arxiv:1903.12394*, 2020.
- [168] P. Battaglia, J. Hamrick, V. Bapst, A. Sanchez-Gonzalez, V. Zambaldi, M. Malinowski, A. Tacchetti, D. Raposo, A. Santoro und R. Faulkner, „Relational inductive biases, deep learning, and graph networks,“ *arxiv:1806.01261*, 2018.
- [169] R. Stewart und S. Ermon, „Label-free Supervision of Neural Networks with Physics and Domain Knowledge,“ *Thirty-First AAAI Conference on Artificial Intelligence*, 2017.
- [170] F. Ahmad, S. A. Mazlan, H. Zamzuri, H. Jamaluddin, K. Hudha und M. Short, „Modelling and Validation of the Vehicle Longitudinal Model,“ *International Journal of Automotive and Mechanical Engineering*, Bd. 10, pp. 2042-2056, 2014.
- [171] Z. Chaochen, C. Hoare und A. P. Raven, „A Calculus of Durations,“ *Information Processing Letters*, Bd. 40(5), pp. 269-276, 1991.
- [172] W. Damm, M. Fränzle, S. Gerwinn und P. Kröger, „Perspectives on the Validation and Verification of Machine Learning Systems,“ *AAAI Spring Symposium Series*, 2018.
- [173] H. Khodabandehlou und M. Sami Fadali, „Training Recurrent Neural Networks as a Constraint Satisfaction Problem,“ *CoRR*, 2018.
- [174] K. Marino, R. Salakhutdinov und A. Gupta, „The More You Know: Using Knowledge Graphs for Image Classification,“ in *CVPR*, 2017.
- [175] C. Lampert, H. Nickisch und S. Harmeling, „Learning to detect unseen object classes by between-class attribute transfer,“ in *Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition, CVPR'09*, 2009.
- [176] I. Flouris, N. Giatrakos, A. Deligiannakis, M. Garofalakis, M. Kamp und M. Mock, „Issues in complex event processing: Status and prospects in the big data era,“ *Journal of Systems and Software*, pp. 217-236, 2017.
- [177] Y. Gal, „Uncertainty in Deep Learning,“ Department of Engineering University of Cambridge, September 2016. [Online]. Available: mlg.eng.cam.ac.uk/yarin/thesis/thesis.pdf. [Zugriff am 24 April 2018].
- [178] I. J. Goodfellow, J. Shlens und C. Szegedy, „Explaining and Harnessing Adversarial Examples,“ in *ICLR*, 2015.
- [179] C. Hubschneider, A. Bauer, J. Doll, M. Weber, S. Klemm, F. Kuhnt und J. Zöllner, „Integrating end-to-end learned steering into probabilistic autonomous driving,“ in *IEEE 20th International Conference on Intelligent Transportation System (ITSC)*, Yokohama, 2017.

- [180] M. Gori, *Machine Learning: A Constraint-Based Approach*, Morgan Kaufmann, 2018.
- [181] R. Evans und E. Grefenstette, „Learning explanatory rules from noisy data,“ *JAIR*, p. 1–64, 2018.
- [182] M. França, G. Zaverucha und A. S. d. Garcez, „Fast relational learning using bottom clause propositionalization with artificial neural networks,“ *Mach. Learning*, p. 81–104, 2014.
- [183] Z. Hu, X. Ma, Z. Liu, E. Hovy und E. Xing, „Harnessing deep neural networks with logic rules,“ in *ACL*, 2016.
- [184] R. Manhaeve, S. Dumancic, A. Kimmig, T. Demeester und L. D. Raedt, „Deepproblog: Neural probabilistic logic programming,“ *Advances in Neural Information Processing Systems*, p. 3749–3759, 2018.
- [185] Q. Wang, K. Zhang, A. G. Ororbia, X. Xing, X. Liu und C. L. Giles, „An empirical evaluation of rule extraction from recurrent neural networks,“ *Neural Computation*, p. 2568–2591, 2018.
- [186] S. N. Tran, „Propositional knowledge representation and reasoning in restricted Boltzmann machines,“ *CoRR*, *abs/1705.10899*, 2018.
- [187] F. Yang, Z. Yang und W. W. Cohen, „Differentiable learning of logical rules for knowledge base reasoning,“ *Advances in Neural Information Processing Systems*, p. 2319–2328, 2017.
- [188] L. Serafini und A. S. d'Avila Garcez, „Learning and reasoning with logic tensor networks,“ in *AI*IA*, 2016.
- [189] R. Borges, A. S. d'Avila Garcez und L. C. Lamb, „Learning and representing temporal knowledge in recurrent networks,“ *IEEE Trans. Neural Networks*, Bd. 22, Nr. 12, p. 2409–2421, 2011.
- [190] A. S. d'Avila Garcez und L. C. Lamb, „Reasoning about time and knowledge in neural symbolic learning systems,“ in *NIPS*, 2003.
- [191] A. S. d'Avila Garcez und L. C. Lamb, „A connectionist computational model for epistemic and temporal reasoning,“ *Neur. Computation*, p. 1711–1738, 2006.
- [192] X. Jia, J. Willard, A. Katpatne, J. Read, J. Zwart, M. Steinbach und V. Kumar, „Physics guided RNNs for modeling dynamical systems: A case study in simulating lake temperature profiles,“ *arXiv:1810.13075v*, 2018.
- [193] D. A. Pomerleau, J. Gowdy und C. E. Thorpe, „Combining artificial neural networks and symbolic processing for autonomous robot guidance,“ *Engineering Applications of Artificial Intelligence*, Bd. 4, Nr. 4, pp. 279–285, 1991.

- [194] P. Sun und et al., „Scalability in Perception for Autonomous Driving: Waymo Open Dataset,“ *arXiv:1912.04838*, 2019.

Berichtsblatt

1. ISBN oder ISSN -	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel KI Wissen – Partnerspezifischer Schlussbericht Valeo Verbundprojekt: KI Wissen - Entwicklung von Methoden für die Einbindung von Wissen in maschinelles Lernen; Teilvorhaben: Wissensbasierte Sensorverarbeitung und Datenaufnahme	
4. Autor(en) [Name(n), Vorname(n)] Müller-Hirschhorn, Christian Pfisterer, Jonas Link, Johannes Khongsab, Peerayut Reuse, Matthias Stehr, Vera Wagner, Tobias Baric, Toni Nagel, Alexander	5. Abschlussdatum des Vorhabens 31.03.2024
	6. Veröffentlichungsdatum 24.07.2024
	7. Form der Publikation Online
8. Durchführende Institution(en) (Name, Adresse) Valeo Schalter und Sensoren GmbH (Verbundpartner) Laiernstrasse 12 74321 Bietigheim-Bissingen Continental Automotive Technologies GmbH Hannover Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung eingetragener Verein München OFFIS e.V. Oldenburg Alexander Thamm GmbH München Capgemini Engineering Deutschland S.A.S. & Co. KG München Bundesanstalt für Straßenwesen (BASt) Bergisch Gladbach FZI Forschungszentrum Informatik Karlsruhe AVL Software and Functions GmbH Regensburg BTC Embedded Systems AG Oldenburg fortiss GmbH München Universität des Saarlandes Saarbrücken e:fs TechHub GmbH Gaimersheim Deutsches Zentrum für Luft- und Raumfahrt e.V. Köln VOLKSWAGEN AKTIENGESELLSCHAFT Wolfsburg Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Kaiserslautern Robert Bosch Gesellschaft mit beschränkter Haftung Gerlingen Deutsches Zentrum für Luft- und Raumfahrt e.V. Köln	9. Ber. Nr. Durchführende Institution Valeo Schalter und Sensoren GmbH
	10. Förderkennzeichen: 19A20020P
	11. Seitenzahl 174
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 194
	14. Tabellen 16
	15. Abbildungen 103
16. Zusätzliche Angaben Titel der pdf-Datei: „KI-Wissen_Valeo_partnerspezifischer Schlussbericht.pdf“	
17. Vorgelegt bei (Titel, Ort, Datum) Technische Informationsbibliothek (TIB), Deutsche Forschungsberichte, Postfach 6080, D-30060 Hannover, 05.06.2024	

18. Kurzfassung

KI Wissen ist ein Projekt der KI Familie. Es wurde aus der VDA Leitinitiative autonomes und vernetztes Fahren initiiert und entwickelt und wird vom Bundesministerium für Wirtschaft und Klimaschutz gefördert. Ein hybrider Ansatz für KI:

Aktuell werden KI-Verfahren weitgehend datenbasiert entwickelt. In der Trainingsphase wird auf Experteneingriffe verzichtet und die KI ausschließlich durch Daten in einem kontinuierlichen Prozess optimiert. Diese Vorgehensweise weist zwei erhebliche Schwächen auf: Für das Training und die Validierung werden enorme Datenmengen benötigt, deren Erhebung und Aufbereitung sehr aufwendig und teuer sind. Darüber hinaus sind datenbasierte KI-Funktionen oftmals Black-Box-Modelle, deren Entscheidungsfindung nicht immer direkt nachvollzogen werden kann.

Bisherige Forschungsansätze konzentrieren sich bei der Lösung dieser Probleme auf die Optimierung der für das Training notwendigen Daten. Das Projekt KI Wissen geht die Herausforderung auf eine neuartige Art und Weise an: Es erforscht, wie sich bekanntes, für den Verkehrskontext relevantes Wissen – in Form von Verkehrsregeln, mathematisch-physikalischen Gegebenheiten und auch sozialen Normen – in KI-Systeme einbinden lässt. Durch diesen hybriden Ansatz, d. h. die Verknüpfung von datenbasierten Verfahren mit wissensbasierten Methoden, wird im Projekt die Basis für das Training und die Validierung der KI-Funktionen komplett neu definiert. Die im Projekt vollzogene Weiterentwicklung von daten- zu informationsbasierter KI adressiert zentrale Herausforderungen auf dem Weg zum autonomen Fahren: die Generalisierung der KI auf Phänomene mit geringer Datengrundlage, die Erhöhung der Stabilität der trainierten KI auf Störungen der Daten, die Dateneffizienz, die Plausibilisierung und die Absicherung von KI-gestützten Funktionen sowie die Steigerung der funktionalen Güte.

19. Schlagwörter

Automatisiertes Fahren, KI, Methoden, Wissensintegration, Wissensextraktion, Wissenskonformität, KI-Wissen, Trainingsdaten, Valeo, synthetische Daten, automatisiertes Lernen, wissensbasierte Architekturen, Datensätze, Gütekriterien

20. Verlag

-

21. Preis

-

Document Control Sheet

1. ISBN or ISSN -	2. type of document (e.g. report, publication) final report
3. title KI Wissen – Partnerspezifischer Schlussbericht Valeo Joint-project: KI Wissen - Entwicklung von Methoden für die Einbindung von Wissen in maschinelles Lernen; sub-project: Wissensbasierte Sensorverarbeitung und Datenaufnahme	
4. author(s) (family name, first name(s)) Müller-Hirsch Korn, Christian Pfisterer, Jonas Link, Johannes Khongsab, Peerayut Reuse, Matthias Stehr, Vera Wagner, Tobias Baric, Toni Nagel, Alexander	5. end of project 31.03.2024
	6. publication date 24.07.2024
	7. form of publication Online
8. performing organization(s) (name, address) Valeo Schalter und Sensoren GmbH (Verbundpartner) Laiernstrasse 12 74321 Bietigheim-Bissingen Continental Automotive Technologies GmbH Hannover Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung eingetragener Verein München OFFIS e.V. Oldenburg Alexander Thamm GmbH München Capgemini Engineering Deutschland S.A.S. & Co. KG München Bundesanstalt für Straßenwesen (BASt) Bergisch Gladbach FZI Forschungszentrum Informatik Karlsruhe AVL Software and Functions GmbH Regensburg BTC Embedded Systems AG Oldenburg fortiss GmbH München Universität des Saarlandes Saarbrücken e:fs TechHub GmbH Gaimersheim Deutsches Zentrum für Luft- und Raumfahrt e.V. Köln VOLKSWAGEN AKTIENGESSELLSCHAFT Wolfsburg Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Kaiserslautern Robert Bosch Gesellschaft mit beschränkter Haftung Gerlingen Deutsches Zentrum für Luft- und Raumfahrt e.V. Köln	9. originator's report no. Valeo Schalter und Sensoren GmbH
	10. reference no. 19A20020P
	11. no. of pages 174
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 194
	14. no. of tables 16
	15. no. of figures 103
16. supplementary notes title of pdf-file: „KI-Wissen_Valeo_partnerspezifischer Schlussbericht.pdf“	
17. presented at (title, place, date) Technische Informationsbibliothek (TIB), Deutsche Forschungsberichte, Postfach 6080, D-30060 Hannover, 22.11.2022	

18. abstract

KI Wissen is a project of the KI family. It was initiated and developed from the VDA flagship initiative for autonomous and connected driving and is funded by the Federal Ministry for Economic Affairs and Climate Action. A hybrid approach to AI: Currently, AI processes are largely developed based on data. In the training phase, expert intervention is avoided and the AI is optimized exclusively through data in a continuous process. This approach has two significant weaknesses: enormous amounts of data are required for training and validation, the collection and processing of which are very complex and expensive. In addition, data-based AI functions are often black box models whose decision-making cannot always be directly traced. When solving these problems, previous research approaches focus on optimizing the data necessary for training. The AI Knowledge project approaches the challenge in a novel way: It researches how known knowledge relevant to the traffic context - in the form of traffic rules, mathematical-physical conditions and also social norms - can be integrated into AI systems. Through this hybrid approach, i.e. H. By linking data-based procedures with knowledge-based methods, the project completely redefines the basis for training and validating AI functions. The further development from data-based to information-based AI carried out in the project addresses central challenges on the way to autonomous driving: the generalization of AI to phenomena with little data, increasing the stability of the trained AI to data disruptions, data efficiency, plausibility and the Securing AI-supported functions and increasing functional quality.

19. keywords

Automated driving, AI, methods, knowledge integration, knowledge extraction, knowledge compliance, AI knowledge, training data, Valeo, synthetic data, automated learning, knowledge-based architectures, data sets, quality criteria

20. publisher

-

21. price

-