



Verbundprojekt:

KIsSME - Künstliche Intelligenz zur selektiven echtzeitnahen Aufnahme von Szenarien- und Manöverdaten bei der Erprobung von hochautomatisierten Fahrzeugen

Schlussbericht zum Teilvorhaben

KI-basierte Situationspotentialbestimmung zur OnBoard Erkennung und Aufzeichnung von Szenarien städtischen Kreuzungsverkehrs

Zuwendungsempfänger	FZI Forschungszentrum Informatik
Förderkennzeichen	19A20026C
Laufzeit des Vorhabens	01.01.2021 - 31.12.2023
Leiter des Teilvorhabens	Daniel Grimm
Telefon	+49 721 9653-372
Email	daniel.grimm@fzi.de
Version	1.0
Erstellungsdatum	20.06.2024



Finanziert von der
Europäischen Union
NextGenerationEU

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

Inhaltsverzeichnis

Inhaltsverzeichnis	2
1 Kurzdarstellung.....	3
1.1 Aufgabenstellung.....	3
1.2 Voraussetzungen des Vorhabens.....	4
1.3 Planung und Ablauf des Vorhabens	7
1.4 Wissenschaftlicher und technischer Stand	8
1.5 Zusammenarbeit mit anderen Stellen	13
2 Eingehende Darstellung	14
2.1 Verwendung der Zuwendung und erzielttes Ergebnis.....	14
2.2 Zahlenmäßiger Nachweis	27
2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit.....	27
2.4 Voraussichtlicher Nutzen.....	28
2.5 Fortschritte bei anderen Stellen	29
2.6 Veröffentlichung der Ergebnisse	30
3 Literaturverzeichnis	30

1 Kurzdarstellung

1.1 Aufgabenstellung

Automatisierte Fahrzeuge müssen in sehr kurzen Zeiträumen (d.h. unter Echtzeitbedingungen) verlässliche Entscheidungen treffen. Die Entscheidungsfindung beruht zumindest teilweise auf Deep-Learning Algorithmen, die nicht deterministisch arbeiten. Als Eingangsgrößen dienen die Werte zahlreicher Sensoren wie Kameras, Radar, Ultraschall, Lidar aber auch klassisch verbauter Sensoren, wie Beschleunigungs- und Geschwindigkeitssensoren. Daher fallen bei der Entwicklung von HAD/AD-Systemen (HAD = hochautomatisiert, AD = autonom) und insbesondere bei deren Erprobung im realen Umfeld sehr große Datenmengen an, die nach derzeitigem Wissen mit herkömmlichen Verarbeitungs- und Analyseverfahren nicht mehr bearbeitet werden können.

Die postanalytische Bewertung und Kontrolle von Fahrfunktionen im Rahmen der Erprobung erfolgte bislang auf Basis einer festen Liste kritischer und relevanter Fahrszenarien sowie aus umfangreichen im Feld aufgezeichneten Datensätzen. Es war offen, wie eine effektive und effiziente Untersuchung von Systemschwächen gerade anhand von seltenen, ungewöhnlichen Fällen aus aufgezeichneten Daten erfolgen kann.

Eine breite Nutzung von KI außerhalb des bekannten Feldes der Sensordatenverarbeitung erfolgte bislang wenig, obwohl ein hoher Bedarf an KI-basierten Methoden gerade für die Erprobung und das entwicklungsbegleitende Testen besteht.

Das Projekt KIsSME wirkte dagegen und setzte KI-Methoden auch für die Effizienzsteigerung von Entwicklung, Test und Validierung von HAD/AD Fahrfunktionen ein.

Die bisherigen Forschungsprojekte erkannten zwar oft das Problem der großen Datenmengen, konnten die damit auftauchenden Probleme aber aufgrund anderer Schwerpunkte nicht lösen. So wurde die echtzeitnahe automatisierte Datenselektion im Fahrzeug (On-Board) ein Alleinstellungsmerkmal des Projekts KIsSME. Zusätzlich war die Verwendung von Szenarien in anderen Forschungsprojekten auf die Postanalyse der Daten sowie insbesondere die Simulation beschränkt. Dort werden theoretisch vorab und top-down erstellte Szenarien benutzt.

Durch den im Projekt KIsSME erarbeiteten Lösungsansatz wurden jedoch bottom-up neue, reale und bislang beispiellose (unexamined) Szenarien erzeugt, die dann auch zur Verwertung durch andere Projekte zur Verfügung stehen.

Durch den Einsatz vor allem von On-Board KI wird damit der HAD/AD-Entwicklungszyklus (Datenerfassung, KI-Training und -Validierung) geschlossen und die Menge der gespeicherten Daten wird signifikant weiter reduziert, wobei die Güte der Daten für das Training von HAD/AD-KIs wächst.

Um reale Szenarien zu erkennen sowie mit bekannt kritischen zu vergleichen und vor allem neuartige zu erkennen wurden existierende KI-Algorithmen benutzt und angepasst, was wiederum eine Neuheit darstellte, z.B. Generative Adversarial Networks (GANs) Algorithmen in diesem Kontext. Durch die KI-basierten Algorithmen zur Datenerfassung für kritische Szenarien besteht zudem die Möglichkeit einer erweiterten Erfassung von nicht Ego-Fahrzeug bezogenen kritischen Szenarien.

Der aktuelle Stand der Technik erlaubt eine konventionelle Verarbeitung von hochauflösenden Lidar- Sensordaten und darüber hinaus die Szenarien-Extrahierung lediglich im Offline-Modus. Die

neuartigen Sensordaten erweitern das heutige Leistungsspektrum von Kamera-basierenden Systemen, ermöglichen neue Anwendungen von KI-Ansätzen und erhöhen die Robustheit und die Fahrsicherheit autonomer Fahrzeuge. Zusätzlich erfassen Lidar-Sensoren keine personenbezogenen Daten und stehen somit im Einklang mit den geltenden Datenschutzrichtlinien. Unter Berücksichtigung des Datenschutzes trägt eine Archivierung und Bereitstellung der durch die KI-extrahierten Testszenarien in standardisierten Formaten nachhaltig zu einem enormen Effizienzgewinn bei.

Neben dem heute üblichen Event-basierten Aufzeichnen wird in Zukunft insbesondere den Verfahren eine hohe Relevanz zugesprochen, welche mit Hilfe von KI selbständig Aufzeichnungen auslösen und markieren. Während des Fahrbetriebs soll entschieden werden, inwiefern es sich bei kontinuierlich anfallenden Daten um relevante, sub-kritische oder gar kritische Ereignisse handelt. Diese sollen extrahiert werden und anschließend in die Verbesserung oder Validierung des Systems einfließen. Das Projekt KISME sollte hierzu Bewertungsverfahren und Kriterien untersuchen, um während des Betriebs mittels Nutzung von maschinellen Lernmethoden Szenarien wiederzuerkennen oder signifikante Abweichungen zu identifizieren.

1.2 Voraussetzungen des Vorhabens

Durch die Expertise der beteiligten Verbundpartner entstand die Möglichkeit ein durchgängiges Konzept für die effektive Datenerfassung von HAD/AD Fahrfunktionen zu erarbeiten und somit einen neuen Stand der Technik zu erzielen.

Das Konsortium setzte sich dabei aus einem Zulieferer (Tier 1), einem Technologieunternehmen, drei innovativen kleinen und mittelständigen Unternehmen (KMU), sowie zwei wissenschaftlichen Einrichtungen zusammen. Zwei assoziierte, nicht geförderte Partner, brachten weitere Kompetenzen in das Projekt ein.

Partner	Kompetenzen und Erfahrungen
AVL Deutschland GmbH (Industrie, Konsortialführung)	Im Projekt KISME brachte AVL Methoden und Werkzeuge zur Erfassung und Aufbereitung kritischer Szenarien für hochautomatisierte Fahrzeuge im urbanen Umfeld ein. Besonders relevant im Kontext des Projekts KISME waren anknüpfende Arbeiten von AVL zum Projekt VV-Methoden (Aufbau und Betrieb von Messfahrzeugen) und dem Projekt SmartLoad (Aufbau und Betrieb virtueller Testumgebungen).
Fraunhofer Institut für Kurzzeitdynamik – EMI (Wissenschaft)	Besonders relevant für KISME waren Projekte im Bereich Sicherheitsnachweis Automotive (Fraunhofer-Projekt FSEM, BMBF Projekte DINA, BMBF-Projekt EVERS SAFE (deu-swe) und BMBF-Projekt InnoTherMS (deu-swe)) und Forschungsprojekte zur Entwicklung von quantitativen Risiko- und Resilienzanalysen sozio-technischer Systeme für neue Anwendungen (u.a. EU Projekte VITRUV, EDEN, XP-DITE, TRESSPASS, RESISTO, CriticalChain, SecureGas, SAFETY4Rails und SATIE), die jeweils einen Transfer von Expertise in der Kritikalitätsbewertung für komplexe Systeme erlauben.

FZI Forschungszentrum Informatik (Wissenschaft)	Im Projekt KisSME brachte das FZI seine interdisziplinären Kompetenzen und Technologien aus den Bereichen Automotive und Autonomes Fahren, Embedded Systems und HW/SW Co-Design sowie von Entwurfs- und Absicherungsverfahren für intelligente Systeme ein. Hierbei wurde auf eine umfangreiche Sammlung von Methoden und Prototypen aus langjährigen Forschungsprojekten zurückgegriffen, wie z.B. Algorithmen aus dem Bereich Fahrerassistenz und autonomen Fahrens sowie Entwurfsmethoden zum HW/SW Co-Design.
Karlsruher Institut für Technologie (Wissenschaft)	Im Projekt KisSME war das Institut für Fahrzeugsystemtechnik (KIT-FAST) beteiligt. Das KIT-FAST war an der Konzeption, am Aufbau und an der Weiterentwicklung des Testfelds Autonomes Fahren Baden-Württemberg (TAF-BW) beteiligt, ist dort für das Arbeitspaket "Fahrzeuge & Services" verantwortlich und baute hierzu unter anderem einen mobilen Leitstand zur Durchführung von Fahrzeugerprobungen auf nahezu beliebigen Streckenabschnitten auf.
LiangDao GmbH (KMU)	Im Projekt KisSME leitete LiangDao das Teilarbeitspaket „Szenarienerkennung“ und stellte nicht nur Cutting-Edge Sensorsystem mit hochauflösenden LiDAR Sensoren im Referenzfahrzeug, sondern auch regelbasierte Verarbeitungssoftware für Objektklassifizierung und Szenarienerkennung. Die gewonnenen Objekte und ihrer technischen Parameter bildeten die essenziellen Datengrundlagen für die KI-relevanten Themen im Projektvorhaben
Mindmotiv GmbH (KMU)	Im Projekt KisSME lagen die Schwerpunkte der Aktivitäten von Mindmotiv bei der Entwicklung und Anbindung von Cloud-Technologien, der Konzeption und Implementierung von Softwaretools und Embedded Software. Insbesondere Aspekte des Datenloggings und der Datenübertragung spielten hierbei eine besondere Rolle.
RA Consulting GmbH (KMU)	Im Projekt KisSME brachte RAC umfangreichen Kenntnisse zu ASAM OpenSCENARIO sowie die Kenntnisse zu den zahlreichen aktuell laufenden und neuen ASAM Standardisierungsarbeiten und -initiativen ein. RA Consulting war maßgeblich für die Entwicklung eines integrierten On Board System mit KI SW Komponenten für die echtzeitnahe Risikoerkennung und selektive Datenselektion.
Robert Bosch GmbH (Industrie)	Besonders relevant im Kontext des Projekts KisSME waren anknüpfende Arbeiten von Bosch im Bereich der Projekte V&V Methoden und KI-Data Tooling sowie Vorarbeiten für fahrerlose Fahrzeugsysteme im Projekt 3F. Durch die in der Forschung und Vorausbildung bei Bosch vorhandene Expertise auf den vorgenannten Gebieten waren die Erfolgsaussichten und die

	Möglichkeiten zur Verwertung der Projekterkenntnisse in hohem Maße gegeben.
ASAM e.V. (Assoziierter Partner)	Im Projekt KisSME konnte ASAM als assoziierter Partner sicherstellen, dass die Projektbeteiligten Zugriff auf die Ergebnisse der laufenden Standardisierungsarbeiten (auch ohne formale Mitgliedschaft im zuständigen Arbeitskreis) und -initiativen erhielten (z.B. OpenX, SOXIL, SOVD), sowie Zugriff auf für das Projekt relevante und verfügbare Standards (z.B. XCP, MDF) erhielten. Über die Zusammenarbeit mit ASAM wurde sichergestellt, dass die Projektergebnisse Einfluss in die laufenden ASAM Standardisierungsarbeiten finden.
e-mobil BW GmbH (Assoziierter Partner)	Im Projekt KisSME wurde das Potenzial der Arbeitsgruppe „Intelligent Move“ genutzt, um im Rahmen von Workshops die Projektinhalte bzw. die bereits erarbeiteten Ergebnisse mit den Fachleuten aus Forschung und Industrie zu diskutieren und Input bzgl. weiterer, praxisrelevanter Aspekte aufzunehmen.

Im Projekt KisSME wurden wesentliche Punkte aus dem Gebiet der Ausschreibung „KI als Schlüsseltechnologie für das Fahrzeug der Zukunft“ mit Schwerpunkt „KI-Verfahren für automatisierte Fahrfunktionen“ des Bundesministeriums für Wirtschaft und Klimaschutz (BMWK) adressiert, siehe ebenfalls Erfolgskontrollbericht.

Neuartige Testverfahren für die Validierung und Freigabe

Langfristig sind für die Absicherung von Fahrfunktionen neue Methoden und Verfahren für die Validierung im Feld und letztlich auch für die Freigabe zu entwickeln. Im Projekt werden neuartige KI-Methoden zum Nachweis des Abdeckungsgrades von relevanten, kritischen und subkritischen Situationen in der Erprobung und damit zur systemischen Gewährleistung der Funktionalität und funktionalen Sicherheit für HAD/AD-Fahrzeugsysteme erforscht, erprobt und im Idealfall validiert. Dies ist gleichermaßen für klassische wie auch KI-basierte Funktionen im Fahrzeug anwendbar. Dies stellt eine wesentliche Grundlage für neuartige Testverfahren für die Validierung und Freigabe dar. Ein Schwerpunkt im Projekt ist die Berücksichtigung der gesetzlichen Vorgaben zum Datenschutz der von Sensoren im Fahrversuch erfassten Daten.

Verbesserte Umfelderkennung, -interpretation und Manöverplanung für die Erprobung

Die im Projekt eingesetzten bzw. weiterentwickelten KI-Methoden sollen nicht nur für die intelligente Szenarienerkennung in Echtzeit eingesetzt werden, sondern auch diejenigen Daten aus Erprobungsfahrten markieren, welche für die weitere Verbesserung der KI-Modelle besonders herangezogen werden sollten (vgl. auch Black Box Funktion bei Unfällen oder Beinahe-Unfällen). Hierbei kommt vor allem solchen Situationen eine entscheidende Rolle zu, in welchen eine kritische Situation durch das System nicht frühzeitig erkannt werden konnte, aber in der Folge auch das Eintreten der Situation nicht erfolgt ist. Weiter können durch Daten die Planung und Durchführung von Fahrzeugerprobungen gezielt unterstützt werden, sodass schlussendlich weitestgehend nur relevante Daten geliefert werden. Dies trägt direkt zu einer verbesserten Umfelderkennung, -interpretation und Manöverplanung für die Erprobung von HAD/AD-Systemen unter Beachtung der gesetzlichen Vorgaben zum Datenschutz von kritischen Sensordaten bei.

1.3 Planung und Ablauf des Vorhabens

Im Projekt KISME wurde ein iteratives und agiles Vorgehen in mit jeweils zugehörigen Meilensteinen zur Projektsteuerung durchgeführt, siehe Abbildung 2.

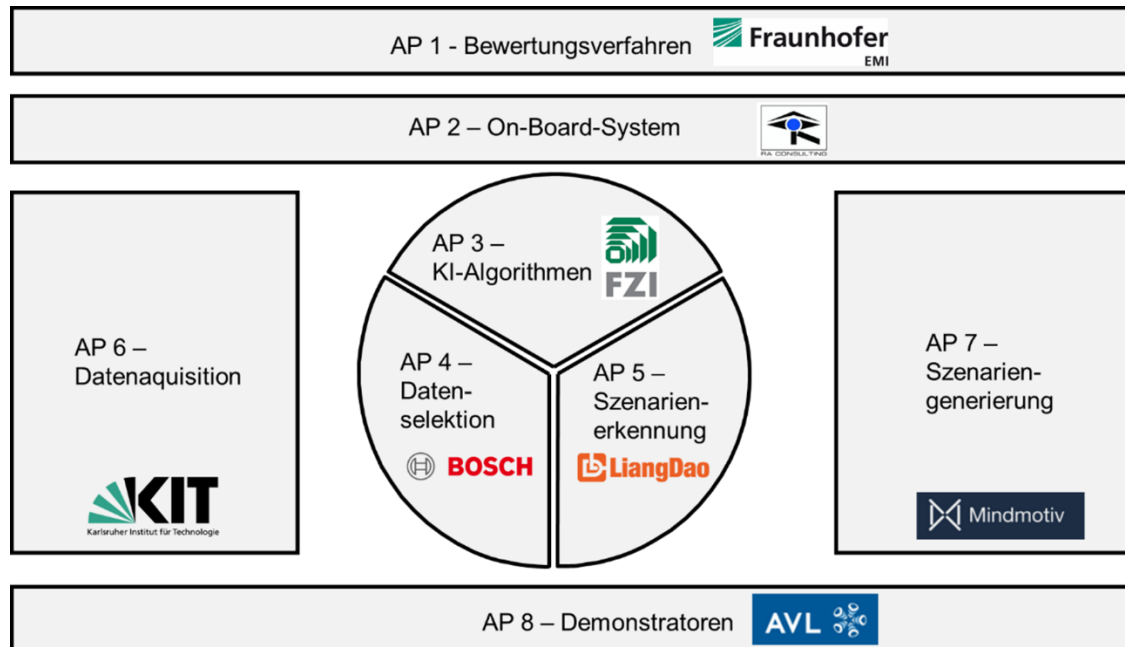


Abbildung 1: Struktur und Schnittstellen der Arbeitspakete im Projekt KISME

AP1 – Bewertungsverfahren (Leitung Fraunhofer Institut für Kurzzeitdynamik)

Risiko-Bewertungsverfahren zur Identifikation und Bewertung kritischer Szenarien in Echtzeit im Fahrbetrieb

AP2 – On-Board-System (Leitung RA Consulting GmbH)

Konzeption, Systemarchitektur und Integration des On-Board-Systems zur KI-basierten Echtzeitüberwachung zur Verbesserung der Datengüte

AP3 – KI-Algorithmen (Leitung FZI Forschungszentrum Informatik)

Adaption von KI-basierten Algorithmen zur echtzeitnahen Anwendung

AP4 – Datenselektion (Leitung Robert Bosch GmbH)

Kriterien zur Datenselektion relevanter Situationen durch Vorhersageabweichung

AP5 – Szenarienerkennung (Leitung LiangDao GmbH)

Entwicklung KI-basiertes Verfahrens zur Erkennung relevanter Szenarien

AP6 – Datenakquisition (Leitung Karlsruher Institut für Technologie)

Anwendung selektive Datenakquisition im realen Umfeld und in Closed-Loop Testumgebung

AP7 - Szenariengenerierung (Leitung Mindmotiv GmbH)

Tool zur automatischen Generierung der standardkonformen Beschreibung von unbekanntem Szenarien zur Verbesserung der Güte von Testverfahren

AP8 – Demonstratoren (Leitung AVL Deutschland GmbH)

Validierung der Ergebnisse an Demonstratoren

AP9 – Projektmanagement (Leitung AVL Deutschland GmbH)

Interne und externe Zusammenarbeit, Verbreitung der Ergebnisse

1.4 Wissenschaftlicher und technischer Stand

Bei derzeitig entwickelten Fahrzeugfunktionen im HAD/AD-Bereich liegt der Fokus auf der Verarbeitung und Sammlung der Daten. So wird beispielsweise anhand von Umfelddaten die Trajektorie und damit die Ansteuerung von Motor und Lenkung berechnet. Um diese Aufgabe sicher in Echtzeit durchzuführen, werden in Fahrzeugen zunehmend leistungsstarke Computereinheiten, sogenannte High-Performance-Computer (HPC) verbaut.

Die nachfolgende Darstellung beschreibt den Stand der Technik zu Projektbeginn:

Formalisierte Darstellung von Automotive Szenarien und Manövern

Die zunehmende Komplexität der Automatisierung von Fahrzeugassistenzsystemen (FAS), automatisierten Fahrfunktionen (AFF) bis hin zum autonomen Fahren selbst, stellt eine enorme Herausforderung an Entwicklungs- und Validierungskonzepte dar. Während klassischerweise vor Marktzulassung eines neuen Fahrzeugmodells oder einer neuen Fahrzeugkomponente die erfolgreiche Absolvierung einer vorgegebenen Anzahl an Testkilometern notwendig ist, kann ein kilometerbasierter Ansatz zum Sicherheitsnachweis von FAS/AFF nicht mehr ökonomisch erbracht werden. Dieses radikale Umdenken in der Automobilbranche und die damit verbundenen Schwierigkeiten und Unsicherheiten spiegeln sich in Forschungsprojekten wie PEGASUS [1], SET Level 4to5 [2], VV-Methoden [3] oder Industrieinitiativen wie u. a. die P.E.A.R.S. Initiative [4], OpenPASS [4] oder OpenADx [5] wieder.

In den genannten Projekten werden verschiedene, vorwiegend virtuelle Methoden und Werkzeuge für die Absicherung von FAS und AFF entwickelt. Generell müssen für eine virtuelle Verifikation von AFF, FAS und autonomen Fahrzeugen durch Verkehrsflusssimulationen alle für die zu testenden Neuerungen relevanten Situationen und Szenarien realitätsgetreu nachgebildet werden.

Die Association for Standardization of Automation and Measuring Systems (ASAM e.V.) arbeitet hier darauf hin, in der Automobilindustrie die Standards OpenDRIVE, OpenCRG und OpenSCENARIO zu etablieren. Diese bilden standardisierte Formate um die zu untersuchenden Szenarien (OpenDRIVE), deren dynamische Eigenschaften (OpenSCENARIO) und die Eigenschaften des Straßenbelages der jeweiligen Szenarien (OpenCRG) virtuell umzusetzen (www.asam.net). Parallel zur Entwicklung von AFF und FAS befinden sich diese Datenformate allerdings in ständigem Wandel.

Event Data Recording

Die dabei anfallenden Daten werden mit Hilfe von Event Data Recorder erfasst und in der Postanalyse verwertet, um die Funktion der HAD/AD-Fahrzeugfunktionen im Labor zu bewerten. Mit steigender Anzahl von Sensoren und Umfang der HAD/AD-Funktionalität ist dies aber aufgrund der enormen Datenmengen immer schwerer realisierbar. Die verwendeten traditionellen

algorithmischen und regelbasierten Ansätze zur Datenselektion skalieren aufgrund der enormen Datenmenge sowie einer sich kontinuierlich verändernden Datenlage absehbar nicht ausreichend, um diesen Anstieg aufzufangen. Diese Herausforderung gilt besonders für Entwicklung und Erprobung, und längerfristig auch für den Betrieb der Fahrzeuge im Sinne der Produkthaftung, der nach rechtlichen Klärungen auch genutzt werden könnte, um potentiell fehlende Szenarien für die Entwicklung und (Langzeit-) Validierung HAD/AD-Systeme bereitzustellen.

Szenariengenerierung

Bei der Analyse dieser Daten und insbesondere bei der Simulation von Testfahrten geraten verstärkt Fahrscenarien zur Entwicklungsunterstützung in den Fokus. Hier sind die Standardisierungsverfahren der ASAM wichtig, welche die bestehenden Standards ASAM OpenSCENARIO, ASAM OpenDRIVE sowie ASAM OpenCRG (zusammen als ASAM OpenX bezeichnet) übernommen und nun weiterentwickelt. Dadurch soll ein einfacher Austausch von Szenarien sowie ein Aufbau einer Szenarienbibliothek (z.B. als ein Use-Case für das vom BMWi und BMBF initiierte Projekt GAIA-X) sichergestellt werden. Bisher werden solche Szenarien weitgehend analytisch top-down und Off-Board (außerhalb des Fahrzeugs) generiert und eingesetzt. Dadurch entsteht die Frage, ob alle tatsächlich auftretenden Szenarien ausreichend erfasst, wurden für eine spätere Systemnutzung (Reduktion des Restrisikos).

Umfeldererkennung (am Beispiel Lidar-Sensoren)

Der Einsatz von kompakten hochauflösenden Lidar-Sensoren ohne bewegliche mechanische Optik für die Umfeldererkennung im autonomen Fahrzeug (Level 3-5) scheint vor dem Hintergrund der Fortschritte der Technologie unabdingbar. Leistungsstarke Lidar-Sensoren ermöglichen eine präzise Objekterkennung durch 3D-Punktwolken mit einer großen Distanz bis zu 200 Metern. Die computergestützte Verarbeitung dieser 3D-Punktwolkendaten liefern präzise ingenieurtechnischen Bewegungsparameter über die Objekte wie Form, Entfernung, Geschwindigkeit und Beschleunigung. Mit Hilfe dieser Objektparameter können anschließend Fahrsituationen erkannt werden. Ein weiterer Vorteil von Lidar-Sensoren ist die Robustheit beim Einsatz unter schlechten Wetterbedingungen und beim starkem Lichtstärkewechsel unter anderen bei Tunnelfahrten. Der Mangel an echtzeitfähigen Verfahren für die On-Board-Auswertung der neuartigen Sensordaten bedeutet einen großen Verlust an Entwicklungspotential.

Prädiktionsverfahren

Automatisiertes Fahren im urbanen Umfeld stellt hohe Anforderungen insbesondere an Prädiktionsansätze zur Bewegungsvorhersage anderer Verkehrsteilnehmer dar, klassische modellbasierte Ansätze gelangen auch schon in einfachen Verkehrssituationen an ihre Grenzen. Die Bewertung der Güte der eingesetzten Ansätze erfolgt häufig nur anhand exemplarischer und vereinfachter Situationen ohne Betrachtung von Rückkopplungseffekten in der Signalverarbeitungskette. Eine Konzeption von Bewertungsansätzen, welche die Beobachtung von Bewegungspfaden anderer Verkehrsteilnehmer im Fahrzeugumfeld automatisch gegenüber den eingesetzten KI-Modellen vergleicht und daraufhin eine Selektion der Daten der aufgezeichneten Umgebungsdaten durchführt, wurde bislang nicht nachgewiesen. Hierfür sollten im Vorhaben multimodale, interaktionsbasierende Prädiktionsverfahren [6], [7] umgesetzt und auf die Anwendung im Versuchsträger erweitert werden.

Simulativ-ingenieurtechnisch Echtzeit-Bestimmung der Kritikalität von Szenarien (On-Board)

Grundlage für die Bestimmung der Kritikalität von Situationen im Straßenverkehr bilden definierte Kritikalitätsmetriken [8]. Für eine Echtzeitbestimmung der Kritikalität von Situationen im Straßenverkehr wird zudem eine Bewegungsprädiktion von Ego- und Objektfahrzeugen benötigt. Diese kann durch die Aufnahme der aktuellen Dynamik der betrachteten Situation, durch bekannte Bewegungsmuster umgebender Fahrzeuge und des Ego-Fahrzeugs selbst und/oder der Identifikation der Situation, in der sich das Ego-Fahrzeug befindet, durch Abgleich zu früheren Situationen, realisiert werden [9].

Es wird zwischen deterministischen und probabilistischen Metriken zur Bewertung der Kritikalität unterschieden. Die Auswahl der jeweils zu verwendenden Metrik hängt von der angestrebten Bewertung und Definition der Kritikalität selbst ab [9]. So erlauben es die Metriken Distance-of-Closest-Encounter (DCE) und Time-to-Closest-Encounter (TTCE) [10] auch eine Bewertung von unfallfreien Situationen, während andere Metriken nur Situationen als kritisch bewerten, die einen Unfall zur Folge haben. Deterministischen Metriken mit dem Ziel Unfälle vorherzusagen, werden allgemein auch als TTX-Metriken bezeichnet.

ML/KI-basierte Generative Generierung von ähnlichen und neuen kritischen Szenarien auf unterschiedlichen Abstraktionsebenen aus Szenario- und empirischen Daten (Off-Board)

Durch Software-in-the-Loop (SiL) Simulationen und Hardware-in-the-Loop (HiL) Echtzeitrechner werden bereits Parameter von Situationen im Straßenverkehr aufgenommen und in Echtzeit derart verändert, dass eine so neu entstehende Situation im folgenden Verlauf durch die angewandte Definition von Kritikalität, als kritisch eingestuft worden wäre. Berechnet werden diese veränderten Parameter durch die oben benannte SiL Simulation. Fahrassistenzsysteme können so in den erzeugten kritischen Situationen getestet werden [11]. Real auftretende kritische Situationen, die Ursache von kritischen Situationen oder die Untersuchung der Sinnhaftigkeit der so generierten kritischen Situationen werden dabei zunächst nicht berücksichtigt. Die Anwendung einer künstlichen Intelligenz zur automatisierten Generierung ähnlicher kritischer Situationen auf der Basis real aufgenommener kritischer Situationen verspricht jedoch validere Ergebnisse bezüglich der Abdeckung aller relevanten kritischen Situationen. Dieser Ansatz wurde zu Beginn des Vorhabens vom State-of-the-Art nicht bedient.

Dies gilt umso mehr, wenn Szenarien abstrakt unter Verwendung von ASAM OpenX Standards dargestellt werden, d.h. Szenario-Variationen vergleichsweise generisch ausfallen müssen im Gegensatz zur Variation von Parametern festgelegter Szenariomodelle. Dies steht im Gegensatz zu ersten Ansätzen zur Verwendung von KI zur besseren Testabdeckung, die unter dem Begriff Design of Experiment bereits vermarktet wird.

In den vergangenen Jahren hat sich die Fähigkeit von generativen KI-Algorithmen wie Variational Autoencoders oder GANs (Generative Adversarial Networks), welche basierend auf bestehenden Daten neue und ähnliche Daten generieren können, stark verbessert. Insbesondere die Erzeugung von täuschend echt aussehenden 2D-Bildern z.B. von Personen hat durch den Einsatz weiterentwickelter GANs wie StyleGAN [12] große Fortschritte gemacht.

Für Bilddaten können diese Verfahren für die Erzeugung von neuen Fahrscenarien eingesetzt z.B., um Bilder mit unterschiedlichen Witterungsverhältnissen zu erzeugen [13]. Die meisten dieser Verfahren beschränken sich jedoch meist auf 2D-Bilddaten und die Übertragung auf andere Datenarten stellt eine Herausforderung dar. So können beispielsweise LiDAR-Daten derzeit nur vereinzelt mithilfe dieser Verfahren erzeugt werden [14], da viele generative Algorithmen nicht auf Punktwolken ausgelegt sind. Ähnliches gilt für die Erzeugung der Daten weiterer Sensoren eines

autonomen Fahrzeugs, um alle Daten bei der Szenengenerierung abzudecken. Für Sensoren, die eine physikalische Messgröße über Zeit aufnehmen, wären generative Algorithmen für die Synthese von Zeitreihen ähnlich wie bei [15] denkbar.

Daher stellt die Erzeugung von ähnlichen und neuen Szenarien-Daten auf der Abstraktionsebene von ASAM OpenX Standards eine neuartige Anwendung dar, die vergleichsweise weite weg von ersten Anwendungen von Generativen Künstlichen Netzwerken (GANs) liegt.

Standardisierungsaktivitäten im Bereich ADAS Simulation

ASAM hat im Jahr 2020 begonnen mit ASAM OpenXOntology einen Standard zu erstellen, der übergeordnet den in der Simulation eingeführten Sprachgebrauch konsistent beschreibt. Dieses Projekt zielt auf die Entwicklung einer offenen ASAM-Ontologie ab, die eine Grundlage gemeinsamer Definitionen, Eigenschaften und Beziehungen für zentrale Konzepte der ASAM-OpenX-Standards bereitstellen soll.

Die Ontologie-Kernkomponenten werden in einer Weise implementiert, die die Erweiterung der OpenX-Standards, einschließlich OpenLABEL, OpenDRIVE, OpenSCENARIO, Open Simulation Interface (OSI) und OpenODD, erleichtert. Der seit Mitte 2020 bearbeitete Ansatz von OpenLABEL besteht darin, eine grundlegende Teilmenge gespeicherter Szenario-Metadaten (z. B. Wetterbedingungen, Manövertypen, Akteure usw.) zu standardisieren, mit dem Ziel, die gemeinsame Nutzung von Daten innerhalb der Gemeinschaft zu erleichtern. Dies hat das Potenzial, die Verfügbarkeit und Zugänglichkeit von Trainings- und Validierungsdaten für autonome Tests exponentiell zu erhöhen. Die Datenmenge ist die Herausforderung der Szenarien basierten Entwicklung oder des Testens. OpenLABEL wird hauptsächlich Konzepte aus der OpenXOntology verwenden, die sich auf die Identifizierung von Entitäten und ihre räumlichen Beziehungen in Bilddaten beziehen. OpenDRIVE wird sich auf die OpenXOntology stützen, um konnektive und räumliche Beziehungen zwischen Elementen der Straßeninfrastruktur und der Verkehrsinfrastruktur zu definieren.

Der Anfang 2020 veröffentlichte Standard OpenSCENARIO 1.0 stellt das Datenmodell, die Spezifikation und Beispiele für die Beschreibung dynamischer Inhalte in der Fahrsimulation zur Verfügung. Es wird in der Fahrsimulation, der Verkehrssimulation, der virtuellen Entwicklung, dem Test und der Validierung von Fahrassistenzfunktionen, dem automatisierten und autonomen Fahren eingesetzt. Die Ziele des in Mitte 2020 beginnenden Projekts OpenSCENARIO 1.x umfassen die Erledigung von Aufgaben, die für V1.0 nicht erfüllt wurden, sowie die Unterstützung von Anwendern und Implementieren. Die in Mitte 2020 begonnene Standardisierung von OpenSCENARIO 2.0 soll als neueres Format und Mechanismus dienen, um allen Test- und Ausführungsplattformen dynamische Inhalte und funktionales Verhalten für alle Fahrszenarien, von einfachen Autobahn-Interaktionen bis hin zu langwierigen, komplexen innerstädtischen Verkehrsszenarien, zur Verfügung zu stellen. OpenSCENARIO 2.0 baut auf dem Konzept einer domänenspezifischen Sprache auf, die alle Ebenen der Szenario-Beschreibung, von sehr abstrakt bis sehr konkret, in geeigneter Weise unterstützen soll. Die Konzepte von OpenSCENARIO 2.0 nehmen bewährte Funktionen und Fähigkeiten von OpenSCENARIO 1.0, wie sein ereignisbasiertes Szenario-Ausführungsmodell, auf und stellen sie in einen allgemeineren und aussagekräftigeren Sprachrahmen, um als Grundlage sowohl für inkrementelle Verbesserungen als auch für revolutionäre Erweiterungen zu dienen. Im Vergleich zu OpenSCENARIO 1.0 soll ein detaillierterer Satz von Aktionen und Attributen für die relevanten Simulationsmodelle definiert werden, um eine umfassendere Szenario-Beschreibung zu ermöglichen und die Austauschbarkeit zu verbessern. Es ist vorgesehen, zukünftige Versionen von ASAM OpenSCENARIO 1.0 bis OpenSCENARIO V2.0 auf eine

gemeinsame Hauptversion zu migrieren. OpenSCENARIO wird sich auf die OpenXOntology stützen, um räumliche und zeitliche Beziehungen zwischen dynamischen und statischen Verkehrsagenten zu definieren. Insbesondere wird die domainspezifische Sprache von OpenSCENARIO 2.0 Konzepte und Beziehungen aus der Kernontologie verwenden, um klare und eindeutige, logisch basierte Definitionen für die Sprachbegriffe bereitzustellen.

OpenSCENARIO verwendet u.a. den in 2020 veröffentlichten OpenDRIVE-Standard, um Informationen zu beschreiben, die sich auf Controller der Straßen- und Verkehrsinfrastruktur beziehen (z.B. Ampeln und Mautstellen). In 2020 wurden bereits die Arbeiten zur Erweiterung des Standards begonnen.

Die offene Simulationsschnittstelle (ASAM OSI) ist eine generische Schnittstelle für die Umgebungswahrnehmung von automatisierten Fahrfunktionen in virtuellen Szenarien. Ihr Ziel ist es, es dem Benutzer zu ermöglichen, jeden Sensor mit einer standardisierten Schnittstelle mit jeder automatisierten Fahrfunktion und mit jedem Fahrsimulator-Werkzeug zu verbinden. Es wurden vier Arbeitsbereiche zur Standardisierung identifiziert: Physikalische Sensormodellierung (d.h. eine bessere Grundwahrheit), Verkehrsteilnehmer & straßenseitige Infrastruktur, OSI-Leistung und -Packaging (z.B. Verbesserungen für Echtzeit) und Harmonisierung mit anderen OpenX-Standards. ASAM OSI wird als Open Source entwickelt. Open Simulation Interface (OSI) wird Konzepte und Beziehungen aus der OpenXOntology verwenden, um die Ground Truth aus Sensormodellen und Sensorfusionsmodellen zu bezeichnen.

Vor dem zu Projektbeginn existierenden Stand der Technik erschien das Hauptziel des Projekts KIsSME, induktiv On-Board kritische und relevante Szenarien für die Entwicklung und Validierung von HAD/AD-Systemen in Echtzeit mit Hilfe von KI-basierten Verfahren zu extrahieren, Off-Board zu konsolidieren und zu erweitern, erreichbar, wobei auf extero-/propriozeptive Sensorik, insbesondere hochauflösendes Lidar, KI-basierte Bewegungsvorhersageverfahren und umfassende HPC-Plattformen gesetzt wurde.

Es waren zu Projektbeginn keine Schutzrechte Dritter bekannt, die der Umsetzung der in KIsSME adressierten Arbeiten entgegenstehen oder die geplante Ergebnisverwertung verhindern könnten. Der Ausbau des patentrechtlichen Portfolios zum Vorteil aller Projektpartner wurde im Kooperationsvertrag geregelt.

1.5 Zusammenarbeit mit anderen Stellen

Zusammenarbeit mit anderen Projekten

Ausgehend von nationalen abgeschlossenen und bestehenden Projekten, die sich mit ergänzenden Fragestellungen beschäftigten, wurde der Kooperation mit anderen Projekten eine hohe Relevanz beigemessen. So wurde insbesondere mit den parallel laufenden Projekten ein enger Austausch praktiziert. Dies konnte zumeist leicht dadurch gewährleistet werden, dass stets mindestens ein KIsSME-Partner auch in den anderen Projekten mitgearbeitet hat. Im nationalen Raum waren insbesondere die Projekte VMMethoden [3], SETLevel [2] und AVEAS [16] von besonderer Bedeutung.

Zusammenarbeit mit anderen Firmen/Einrichtungen

Im Projekt KIsSME wurden ein Austausch mit folgenden Einrichtungen bzw. Firmen durchgeführt:

- Lieferanten aus dem Bereich Datenlogging
- Lieferanten aus dem Bereich Simulationstechnologie
- mehrere KMUs aus dem Bereich Data Analytics
- Einrichtungen aus dem Bereich Verkehrsunfallforschung
- Workshops mit Standardisierungsgremium ASAM e.V. wie z.B. über OpenTEST

2 Eingehende Darstellung

2.1 Verwendung der Zuwendung und erzielttes Ergebnis

2.1.1 AP1 - Bewertungsverfahren

Ziel von Arbeitspaket 1 (AP1) - Bewertungsverfahren war es im Wesentlichen, die Grundlagen für ein Bewertungssystem zu schaffen, welches in der Lage ist Verkehrsszenarien aus der Ego-Perspektive eines Fahrzeugs bezüglich dessen Relevanz für eine Aufnahme zu bewerten. Die Relevanz von Fahrerszenarien wurde dabei an eine sicherheitskritische Bewertung angelehnt. In AP1 wurden zudem die rechtlichen Grundlagen für die datenschutzkonforme Verwendung der im Projekt verarbeiteten Daten identifiziert und kommuniziert. Das FZI trug Arbeitsinhalte in TAP 1.2 und 1.3 bei.

Das FZI hat in TAP 1.2 die Anforderungen der HW-Plattform an die analytischen Szenarienbewertung überprüft. Bei der Ableitung der Kritikalitätsgrößen aus Situationsanalysen und der nachfolgenden Einbettung in Relevanzmetriken wurde unterstützt, sodass zum Abschluss des TAP eine umfangreiche Liste zur Verfügung stand. Die wichtigsten Metriken sind in Tabelle 1 genannt. In TAP 1.3 wurde vom FZI eine mögliche Nutzung des Datenformats OpenSCENARIO in KI-Algorithmen untersucht. Hierbei zeichnete sich ab, dass OpenSCENARIO mit Fokus zur Verwendung in Simulationsprogrammen entwickelt wurde. Solange die Daten für den KI-Algorithmus aus einem Simulationsprogramm stammen, steht einer Verwendung von OpenSCENARIO nichts im Wege. Sollen allerdings reale Daten genutzt werden, ist ein Einsatz von OpenSCENARIO nicht zu empfehlen, da die reale Umgebung unsicherheitsbehaftet ist und vor allem nicht vollständig erfassbar und einsehbar ist, z.B. verdeckte Verkehrsteilnehmer. Die Daten werden somit nicht den Erwartungen von OpenSCENARIO gerecht.

Tabelle 1: Liste der wichtigsten Metriken

v_lon	Momentane longitudinale Geschwindigkeit des Ego-Fahrzeugs
a_lon	Momentane longitudinale Querbeschleunigung des Ego-Fahrzeugs
a_lat	Momentane laterale Querbeschleunigung des Ego-Fahrzeugs
δ	Momentaner Lenkwinkel des Ego-Fahrzeugs
d_CE	Distance-of-Closest-Encounter: Distanz zwischen Ego-Fahrzeug und einem Referenzfahrzeug/Objektfahrzeug bei einer Passierung (TTCE=0) unter der Voraussetzung, dass die aktuellen Trajektorien und fahrdynamischen Parameter beibehalten werden.
t_TB	Time-to-Break: Zeit, die verbleibt bis zu dem Zeitpunkt, eine Kollision zwischen Ego-Fahrzeug und vorausfahrendem Fahrzeug durch eine maximale Verzögerung zu verhindern, unter der Voraussetzung, dass die aktuellen Trajektorien und fahrdynamischen Parameter beibehalten werden.
t_TC	Time-to-collision: Zeit bis zu einer Kollision zwischen Ego-Fahrzeug und vorausfahrendem Fahrzeug, unter der Voraussetzung, dass die aktuellen Trajektorien und fahrdynamischen Parameter beibehalten werden
t_CE	Time-to-Closest-Encounter: Zeit die verbleibt bis die Distanz zwischen Ego-Fahrzeug und einem Referenzfahrzeug/Objektfahrzeug bei einer Passierung minimal wird unter

	der Voraussetzung, dass die aktuellen Trajektorien und fahrdynamischen Parameter beibehalten werden.
t_HW	Time-Head-Way: Zeitspanne, die vergeht bis das Ego-Fahrzeug die Distanz zwischen ihm und einem vorausfahrenden Referenzfahrzeug/Objektfahrzeug (DHW) zurückgelegt hat, unter der Voraussetzung, dass die aktuellen Trajektorien und fahrdynamischen Parameter beibehalten werden.

2.1.2 AP2 – On-Board-System

Das AP 2 – Konzeption, Systemarchitektur und Integration des On-Board-Systems zur KI-basierten Echtzeitüberwachung zur Verbesserung der Datengüte – befasst sich mit der Spezifikation, Entwicklung und Umsetzung eines On-Board Systems zur KI-basierten Überwachung der Szenarien und Datenselektion.

In TAP2.2 arbeitete das FZI mit an der Konzeptionierung der Systemarchitektur des On-Board-Systems. Als zu Grunde liegendes Framework wurde gemeinsam mit den Partnern das Robot Operating System (ROS) ausgewählt. Hierbei liegt der Vorteil vor allem in der Modularität, sodass Komponenten für das Referenzsystem ausgetauscht und durch Komponenten verschiedener Partner leicht ersetzt werden können. Als Trigger dient der skalare Kritikalitätswert, der aus dem Kritikalitätsalgorithmus stammt.

In TAP2.3 hat das FZI nach umfangreicher Recherche von möglichen Software-Architekturkonzepten sich für eine Lösung mit Buffer entschieden. Grund hierfür ist die Latenz (<100ms) des Risikoalgorithmus, sowie mögliche Unsicherheiten in der Risikoerkennung. Als mögliche Speicherformate wurden das .mdf und das .bag Format identifiziert. Als beste Lösung erwies sich das auf ROS aufsetzende System rosbag_snapshot. Es kombiniert die einfache Handhabung des Aufnahmetools Rosbag mit einem RAM-basierten Buffersystem. Die Buffergröße ist konfigurierbar und wurde im Projekt auf 30s gesetzt. Eine Aufnahme kann über einen Servicecall innerhalb des ROS-Ökosystems gestartet werden. Die Aufnahme enthält die Daten im Buffer und die folgenden 30s. Geloggt werden alle verfügbaren Daten. Beim Versuchsträger CoCar NextGen (AP5 – Szenarienerkennung) werden in der einminütigen Aufnahme bereits mehr als 40 GB an Speicherplatz benötigt.

Im Rahmen von TAP 2.4 hat das FZI eine Ethernet-basierte Basler-Kamera in die aus AP3 – Algorithmen stammende eingebettete FPGA-Lösung, als Erweiterung des HPCs, integriert. Die notwendige Datenkommunikation zwischen dem integrierten ARM SoC, der das Kamerabild empfängt und somit die Schnittstelle des Device darstellt, und dem FPGA, der die eigentliche Datenverarbeitung realisiert, wurde umgesetzt. Hierzu wurde ein ROS2-Laufzeitsystem für die Embedded-Plattform adaptiert und kompiliert. Neben der Inbetriebnahme von ROS2 auf dem eingebetteten System wurde das gesamte ROS-System konfiguriert und entsprechende Adapter umgesetzt. Das System ist für die Weiterleitung der Kameradaten an den eigentlichen Hardwarebeschleuniger verantwortlich. Weiterhin konvertiert das System die Ausgabe des KI-Algorithmus, welcher im FPGA realisiert wurde, in ein Standardformat, damit dieses von standardisierten ROS-Knoten weiterverwendet werden kann. Zum Abschluss des TAP wurde die gesamte Verarbeitungspipeline mit simulierten Szenarien als Input validiert.

Im Rahmen des TAP2.5 wurde der HPC im Versuchsträger CoCar NextGen verbaut, sowie an die weitere Fahrzeuginfrastruktur (Netzwerk, CAN, Sensorik) angebunden. Der HPC liefert hierbei einen wichtigen Bestandteil des Versuchsträgers, und wird weiterhin für die Integration und Erprobung verschiedener On-board-Funktionen verwendet.

2.1.3 AP3 – Algorithmen

Im Rahmen des AP3 – Adaption von KI-basierten Algorithmen zur echtzeitnahen Anwendung – wurden Building-Blocks (Bibliotheken, PoC-Realisierungen sowie Best-Practices) von Software- und Hardwarekomponenten entwickelt sowie deren Architekturintegration zur echtzeitfähigen Umsetzung von KI-Algorithmen. Das Ziel des FZIs in AP3 war die beschleunigte Ausführung von KI-Algorithmen durch Hardware-Unterstützung.

In TAP 3.1 wurden KI-basierte Detektionsalgorithmen evaluiert, bspw. EfficientDet [17] und Yolo [18]. Sie wurden nicht nur im Hinblick auf ihre Genauigkeit bei der Objekterkennung und -klassifizierung bewertet, sondern auch darauf, wie gut sie auf den verfügbaren Beschleunigern, die in TAP 3.2 bewertet wurden, ausgeführt werden können.

In TAP 3.2 wurden Beschleuniger, wie bspw. NVDLA, TVM-VTA oder Gemini, auf ihre Anwendung im Kontext von KisSME evaluiert. Im Rahmen dieses TAPs wurde die Integration des Gemini-Beschleunigers in das RocketChip-Generatoren-Framework vorangetrieben. Sowohl der Gemini-Beschleuniger als auch der RocketChip-Generator stellen parametrisierbare Basiskomponenten dar, welche anwendungsspezifisch konfiguriert bzw. instanziiert werden können. Neben der Integration des Beschleunigers in die Hardware wurde der Gemini-Beschleuniger auch in das TVM Deployment Framework integriert. Das Framework ermöglicht dem Anwender ML-Modelle einfach auf einem Beschleuniger nutzen zu können, d.h. es übernimmt das Mapping von Operationen auf den Hardware-Beschleuniger. Diese SW Integration wurde als Open-Source veröffentlicht¹ und auf der Konferenz „CODAI 2022 Workshop on Compilers, Deployment and Tooling for EdgeAI“ präsentiert.

Zur Validierung wurde ein auf der EfficientDet-Architektur basierender Objektdetektor auf einem FPGA mit einem Rocket-Chip-SoC und einem Gemini-Beschleuniger implementiert. Mehrere EfficientDet-Modelle wurden getestet, um den besten Kompromiss zwischen Modellgröße, Anzahl der Operationen für einen Inferenzdurchlauf und Genauigkeit zu finden. Es wurde auch an der Optimierung des Scheduling der Beschleunigeranweisungen mit Hilfe des TVM Deployment Framework gearbeitet, um die Netzwerkschichten noch schneller auszuführen.



Abbildung 2: FPGA-basierten Beschleunigers mit EfficientDet Ergebnisse, evaluiert auf simulierte Daten.

¹ [\[microTVM\]Gemini code generation using microTVM by fzi-peccia - Pull Request #13770 - apache/tvm · GitHub](https://github.com/fzi-peccia/microTVM/pull/13770)

2.1.4 AP4 – Datenselektion

Das Arbeitspaket 4 – Kriterien zur Datenselektion relevanter Situationen durch Vorhersageabweichung – befasste sich mit der Auswahl und Implementierung geeigneter modellbasierter und datengetriebener Metriken, der dafür benötigten Datenquellen, sowie der auf Basis dieser Metriken zu treffenden Aufnahmeentscheidung.

Das FZI hat in TAP 4.1 bei der Auswahl der Metriken unterstützt. Hierbei stand vor allem die mögliche Umsetzung im Versuchsfahrzeug im Mittelpunkt. Als limitierender Faktor wurde die geplante Sensorik und die sich daraus ergebenden Grenzen bei der Umgebungswahrnehmung, sowie die herstellerseitigen Beschränkungen beim Zugriff auf den Fahrzeug CAN-Bus identifiziert. Als vielversprechendstes Datenselektionskriterium stellte sich die Abweichung zwischen prädizierter Zukunft und tatsächlich eingetretener Szene heraus. Eine Recherche nach möglichen Umgebungsmodellierungen von Fahrsituationen zur späteren Verwendung in KI-Algorithmen wurde durchgeführt. Es stellte sich die Modellierung über Objektlisten für Verkehrsteilnehmer und Graphen für die Straßentopologie als besonders geeignet heraus. Im Vergleich zu Grids besteht für ML-Algorithmen hierbei aufgrund geringerer Speichergröße der Vorteil eines effektiveren Trainings sowie einer schnelleren Verarbeitung. Als mögliche Architekturen wurden Transformer und Graph Neuronale Netze näher untersucht. Beide Architekturen bieten den großen Vorteil, dass die Eingangsdaten Sequenzen von dynamischer Länge sein können. Diese Eigenschaft ist essentiell, da die Anzahl der Verkehrsteilnehmer und die Anzahl der Straßen in einer Verkehrsszene variabel sind. Graph Neuronale Netze bieten darüber hinaus den Vorteil, dass die Architektur modular ist und durch weitere Knoten und Kantentypen leicht erweitert werden kann. Um den zukünftigen Verlauf einer Verkehrsszene verlässlich abschätzen zu können, wurde in AP4 vom FZI das Graph-basierte Prädiktionsmodell HoliGraph entwickelt.

In TAP 4.2 fand eine umfangreiche Recherche bestehender Vorhersagemodelle statt. Hierbei sei vor allem auf die Arbeit von Liang [19] verwiesen, auf deren Grundlage das Modell HoliGraph in diesem Projekt entwickelt wurde.

Referenz	Titel	Architektur
[19]	Learning Lane Graph Representations for Motion Forecasting	GNN
[20]	AgentFormer: Agent-Aware Transformers for Socio-Temporal Multi-Agent Forecasting	Transformer
[21]	HDGT: Heterogeneous Driving Graph Transformer for Multi-Agent Trajectory Prediction via Scene Encoding	GNN
[22]	HiVT: Hierarchical Vector Transformer for Multi-Agent Motion Prediction	Transformer
[23]	LAformer: Trajectory Prediction for Autonomous Driving with Lane-Aware Scene Constraints	Transformer
[24]	FJMP: Factorized Joint Multi-Agent Motion Prediction over Learned Directed Acyclic Interaction Graphs	GNN

Als sinnvolle Bewertungsmetriken stellten sich bei der unimodalen Bewegungsvorhersage der Average Displacement Error (*ADE*) und der Final Displacement Error (*FDE*) heraus. Bei

multimodalen Vorhersagen erwiesen sich die oft in der Literatur verwendeten Minima $minADE$ und $minFDE$ als nicht sinnvoll, da bei der Gütebestimmung die vorhergesagten Trajektorien nicht mit ihrer Eintrittswahrscheinlichkeit gewichtet werden und diese somit nicht berücksichtigt wird. Für die nachfolgende Ermittlung der Prädiktionsabweichung sind Eintrittswahrscheinlichkeiten bei multimodalen Bewegungsvorhersagen jedoch essenziell, da sich die Abweichung auf die am wahrscheinlichsten einzutreffende(n) Trajektorie(n) bezieht. Als sinnvolle Maße zur Gütebestimmung erwiesen sich hier die um den Brier-Score erweiterten Fehlermaße $minADE_{brier}$ und $minFDE_{brier}$, welche wie folgt definiert sind:

$$minADE_{brier} = \frac{1}{AT_f} \sum_a^A \sum_t^{T_f} (1 - p_{k_{min}})^2 + \min_k \|\tau_a^{t,k} - \hat{t}_a^t\|^2$$

$$minFDE_{brier} = \frac{1}{A} \sum_a^A (1 - p_{k_{min}})^2 + \min_k \|\tau_a^{T_f,k} - \hat{t}_a^{T_f}\|^2$$

Hierbei entspricht A der Anzahl der Agenten, T_f dem Prädiktionshorizont, τ der prädizierten Trajektorie, \hat{t} der wahren Trajektorie, sowie p der geschätzten Eintrittswahrscheinlichkeit der zugehörigen Trajektorie.

In TAP 4.3 entwickelte das FZI das eigene Modell HoliGraph zur Bewegungsvorhersage. Es basiert auf einem heterogenen Graphen, welcher aus diversen Knoten und Kanten von unterschiedlichen Typen besteht. Die Knoten vom Type *map* bestehen aus Segmenten der Fahrzeugmittellinie und enthalten die Position und sowie die Fahrtrichtung der Mittellinie. Die Verkehrsteilnehmer werden in road-bound und non-road-bound klassifiziert. Knoten dieser Typen enthalten Informationen über einen Verkehrsteilnehmer zu einem bestimmten Zeitpunkt, wie z.B. Position, Geschwindigkeit und Zeitstempel. Die Knoten im Graph sind über viele verschiedene Kantentypen vernetzt und können damit über das so genannten Message Passing im Graph Neuronalen Netzwerk Informationen untereinander austauschen. HoliGraph implementiert eine Encoder-Decoder Architektur. Der Encoder besteht aus einem Graph Neuronalen Netz und gibt für jeden Agenten in der Verkehrsszene einen Featurevektor der Größe [128] aus. Der Decoder besteht aus K Köpfen, welche jeweils aus einem Multi Layer Perceptron (MLP) bestehen. Jeder Kopf gibt für jeden Agenten eine Trajektorie mit einer geschätzten Eintrittswahrscheinlichkeit aus. Auf der ICRA (<https://www.icra2023.org/>) des IEEE Robotics and Automation Chapters mit 6601 Teilnehmern in London konnte das FZI das in KIS SME entwickelte Prädiktionsmodell „HoliGraph“ der Forschungscommunity vorstellen. Weitere Informationen finden sich in der wissenschaftlichen Veröffentlichung unter: <https://doi.org/10.1109/ICRA48891.2023.10161468>

Im Folgenden wird näher auf den Aufbau des Encoders eingegangen. Dieser besitzt drei Subnetze, siehe Abbildung 3. Das Agentnet bildet den zeitlichen und sozialen Zusammenhang zwischen den Verkehrsteilnehmern an. Das Mapnet verarbeitet den Straßengraphen. Im Fusionnet werden die Informationen zwischen Verkehrsteilnehmern und Karte letztendlich ausgetauscht. Im letzteren werden auch Ankerpfade genutzt. Dies sind potenzielle Pfade, die ein Verkehrsteilnehmer entsprechend des zugrunde liegenden Straßennetzwerks fahren kann, siehe Abbildung 5. Dabei zeigt sich vor allem in Kreuzungsbereichen eine verbesserte/variantenreichere Bewegungsvorhersage, siehe Abbildung 4.

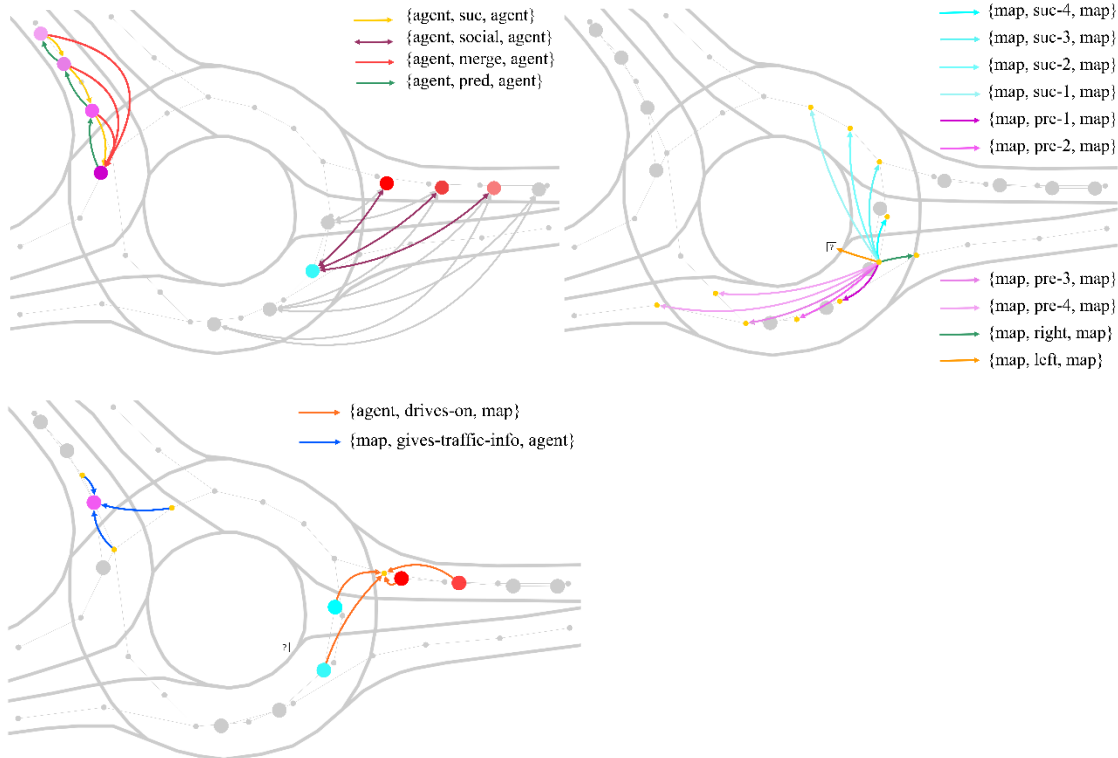


Abbildung 3: Verschiedene Kantentypen im GNN. Von Oben rechts nach unten links: Agentnet, Mapnet, Fusionnet

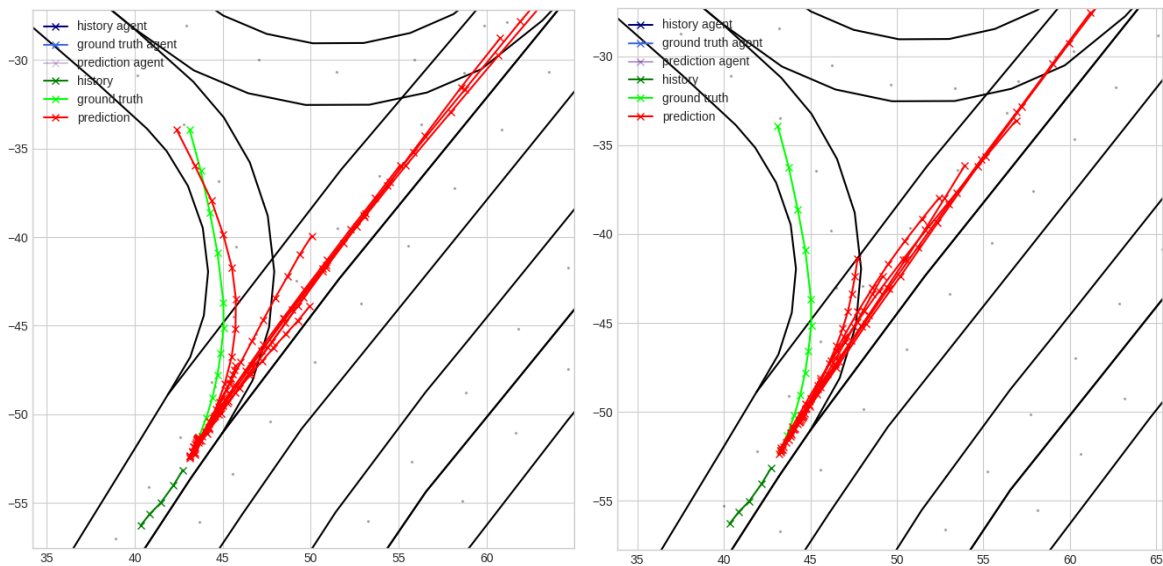


Abbildung 4: Links: Verwendung von Ankerpfaden. Rechts: keine Verwendung von Ankerpfaden.

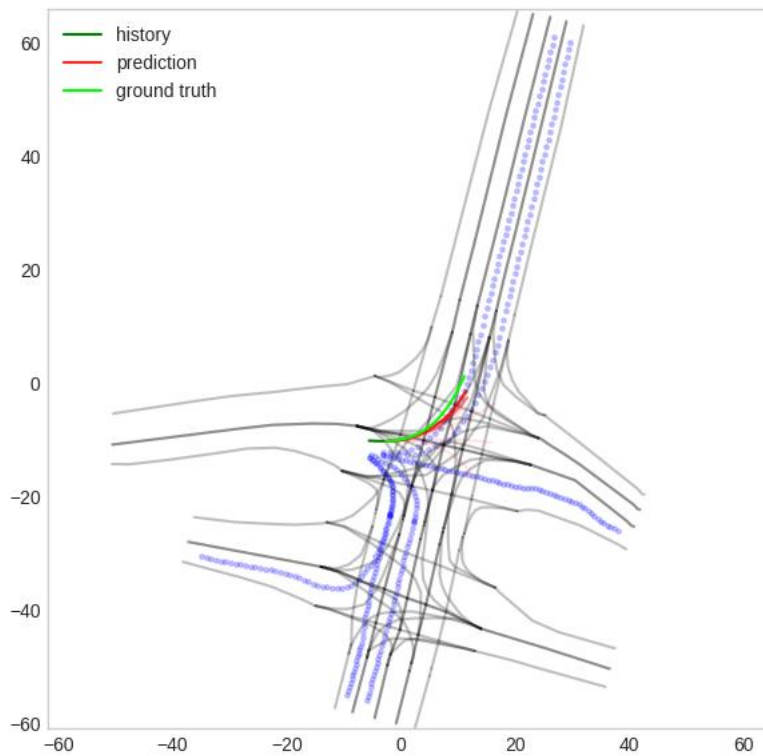


Abbildung 5: Ankerpfade für den Agenten in blau gekennzeichnet

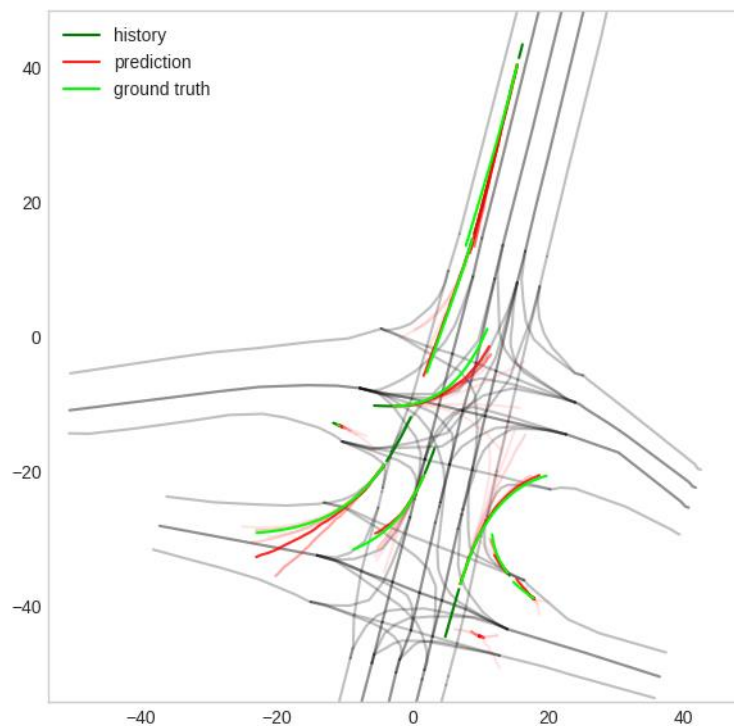


Abbildung 6: Bewegungsvorhersage einer Verkehrsszene aus dem Interaction-Datensatz. Dabei werden die vergangene Trajektorie in dunkelgrün, die wahre zukünftige Trajektorie in hellgrün, die verschiedenen Trajektorien in Rottönen, wobei die Intensität für die Eintrittswahrscheinlichkeit der Trajektorien stehen, dargestellt. Die schwarzen Fahrbahnränder sind für den Betrachter eingezeichnet, werden aber nicht an die KI übergeben.

In TAP4.4 wurde analysiert, inwieweit ein Stresslevel der HAD -Funktion aus der Bewegungsvorhersage extrahiert werden kann. Typischerweise geben KI-basierte Modelle zur Bewegungsvorhersage K mögliche Zukünfte aus. Im Stand der Technik wird häufig $K=6$ gesetzt. Durch den Buffer im Loggingsystem muss eine Aufnahme nicht frühestmöglich gestartet werden. Es empfiehlt sich so lange zu warten, bis überprüft werden kann, ob eine der vorhergesagten Bewegungsverläufe tatsächlich eingetroffen ist. Ist das nicht der Fall, liegt die Vermutung nahe, dass ein hohes Stresslevel der HAS-Funktion vorliegt. Soll eine Entscheidung frühestmöglich getroffen werden eignet sich die Szenenkonsistenz SCR zum Überprüfen des Stresslevels. Hierzu wird der relative Anteil der inkonsistenten Szene errechnet. Eine Szene gilt als inkonsistent, wenn eine Kollision stattfindet. Durch die Versuchsfahrten in TAP 6.2 konnte empirisch folgende Funktion aufgestellt werden, α dient zur Normalisierung:

$$str_{lvl} = \max(SCR, \alpha * \min FDE_{brier}); \quad \alpha = 0.95 \frac{1}{m}$$

str_{lvl} kann damit Werte im Bereich $[0;1]$ annehmen.

In TAP4.5 wurden die Prädiktionsabweichung prototypisch in den Logger aus AP2 integriert.

2.1.5 AP5 – Szenarienerkennung

Das Arbeitspaket 5 befasste sich mit KI-Verfahren zur Erkennung relevanter Szenarien aus Sensorrohdaten, sowie dem Aufbau von Versuchsfahrzeugen und der Integration der entwickelten Systeme in diesen.

In TAP 5.1 führte das FZI umfangreiche Integrationsarbeiten durch. Zum einen wurde das KIT bei der Auswahl der Lidar Sensoren und der Lokalisierungseinheit für ihr Versuchsfahrzeug unterstützt. Zum anderen wurde der FZI-Versuchsträger CoCar NextGen in Betrieb genommen. Hierbei wurde die Software-Ansteuerung der Aktorikeinheit, Paravan Space-Drive, getestet. Parallel dazu wurde das Konzept für die Hardware- und Software-Architektur entwickelt. Auf Basis dieser Konzeptarbeiten wurde die HPC-Einheit, eine MicroAutoBox III der Firma dSPACE beschafft und in das Fahrzeug verbaut.



Abbildung 7: Magnetmounts für CoCar zur Anbringung neuerer Sensorik

Leider sorgten bei Aufbau und Umrüstung des Versuchsträgers CoCar NextGen an vielen Stellen Materialknappheit wie die Chipkrise und globale Lieferkettenengpässe zu großen Verzögerungen in den Lieferzeiten der Hardware-Komponenten. Um die Auswirkungen dieser Verzögerungen

kompensieren zu können, wurde als temporäre Alternative der Vorgänger "CoCar" mittels zweier Magnetmounts und Dachträger-Aufbauten mit Sensorik ausgestattet und somit temporär für das KisSME Projekt zur Sensorrohdatenerfassung nutzbar gemacht. In CoCar war aufgrund der eingeschränkten Rechenleistung keine On-Board Verarbeitung möglich. Diese fand nach der Aufrüstung auf CoCar NextGen statt.

Schließlich wurden im Projekt entwickelte Softwarekomponenten, wie z.B. die in AP5.3 beschriebene Umfeldwahrnehmung auf CoCar NextGen integriert und erprobt.




Abbildung 8: Ausgabe des in TAP 5.3 entwickelten Perzeptionsalgorithmus auf Lidar-Daten des Versuchsträgers CoCar NextGen. S. Abbildung 9 in TAP 5.3 für eine detailliertere Beschreibung der Farbgebung und Funktionalität.

In TAP 5.3 wurde eine neue KI-basierte semantische Methode entwickelt, um Lidar-Punktwolken in Voxel-Rastern effizient zu verarbeiten, um punktweise Objektklassifizierung zu erhalten. Hierbei wurden eigens effiziente GPU-Implementationen von Performance-kritischen Operationen entwickelt, die eine echtzeitfähige Verarbeitung hochauflösender Lidar-Scanner ermöglichen. Die Methode wurde bereits erfolgreich auf dem öffentlichen SemanticKITTI-Datensatz trainiert, und erreicht dort mit einem mIoU-Score von 57.5% ein Ergebnis, welches aktuellen State-of-the-Art Methoden gleicht, und gleichzeitig echtzeitfähig ist. Das entwickelte Perzeptionsverfahren wurde anschließend in mehreren FZI-Versuchsträgern, inklusive dem in TAP5.1 aufgebauten Versuchsträger CoCarNextGen integriert und evaluiert. Es verarbeitet Sensordaten von Lidar-Sensoren, um höherwertige Informationen wie die Objektklasse (Fahrzeug, Fußgänger, Boden, etc.)

für andere Fahrfunktionen sowie die im KisSME-Vorhaben umgesetzte Aufnahme-Triggerfunktion zur Verfügung zu stellen. Die folgende Visualisierung zeigt die Ausgabe der Punktwolken-Segmentierung als Aufnahme des Versuchsträgers. Fahrzeuge (orange) sowie Wände (blau) und andere Hindernisse sind klar zu erkennen. Aus den Analysearbeiten, die zur Performance-Optimierung in TAP 5.3 hervorgegangen sind, wurde das wissenschaftliche Paper „Analyzing Deep Learning Representations of Point Clouds for Real-Time In-Vehicle LiDAR Perception“ auf dem Workshop „Machine Learning for Autonomous Driving“ der Konferenz „Neural Information Processing Systems“ im Dezember 2022 veröffentlicht. Es befasst sich mit den verschiedenen Repräsentationen von Lidar-Punktwolken in tiefen neuronalen Netzen für die Umfeldwahrnehmung, und deren Einfluss auf Laufzeitcharakteristika in Versuchsträgern und automatisierten bzw. autonomen Fahrzeugen. Das Paper wurde auf der Konferenz in New Orleans auf dem Workshop vorgestellt, und in der dortigen Poster Session diskutiert.




Abbildung 9: Erprobung der Lidar-Perzeptions-Algorithmen auf einem FZI-Versuchsträger mit vier Lidar-Sensoren. Der Perzeptionsalgorithmus filtert die Bodenebene aus den Punktwolken der verschiedenen Sensoren und weist den Punkten, die anderen Objekten angehören, entsprechende Objektklassen (hier farblich dargestellt) zu.

In TAP5.4 fand die Integration, der vom FZI in AP4 – Datenselektion entwickelten Bewegungsvorhersage in das in AP1 entwickelte Risikomodell statt. Der Fokus der Integrationsarbeit richtet sich dabei vor allem auf die Handhabung mehrerer Bewegungsvorhersagen pro Verkehrsteilnehmer und die Kondensierung dieser zu einem ganzheitlichen Risiko. Während der Projektlaufzeit leitete das FZI mehrere konsortiumübergreifende Treffen zur Erstellung eines gemeinsamen Risikoalgorithmus. Hierzu fanden mehrere Diskussionsrunden zur Definition der Schnittstellen statt. Die finalisierten Schnittstellen wurden in das projektinterne Gitlab, für alle Partner zugänglich, überführt. Die Integration erster Metriken in das bestehende Framework fand im Anschluss in einem gemeinsamen Termin statt. Anschließend folgte die Integration der Bewegungsvorhersage „HoliGraph“. Die Parametrierung erwies sich allerdings als komplex, da multimodale Bewegungsvorhersagen nicht

immer szenenkonsistent sind. Für HoliGraph bedeutete, dass es in 15% aller prädierten Szenen auf dem INTERACTION Validierungsdatensatz [25] zu einer Kollision kam. In der Ground Truth des Datensatzes findet allerdings keine einzige Kollision statt. Damit konnte in diesem Projekt die multimodale Trajektorienprädiktion prototypisch an den Risikoalgorithmus angebunden werden.

2.1.6 AP6 – Datenakquisition

Das Arbeitspaket 6 befasst sich mit der selektiven Datenakquisition im realen Umfeld sowie in Closed-Loop Testumgebungen. Das FZI trug Arbeitsinhalte in TAP 6.2 - der Durchführung der Testfahrten bei. Hierfür wurde der HPC von DSPace und das Kamerasystem, bestehend aus zwei Basler Kameras, in CoCar NextGen integriert und verknüpft. Das FZI beteiligte sich an allen vier Versuchstagen:

1. 01.12.2021: Privatgelände - Campus Ost
2. 25.05.2022: Privatgelände - Campus Ost
3. 19.10.2022: Privatgelände - Campus Ost
4. 04.04.2023: Öffentlicher Straßenverkehr – Stadt Karlsruhe

An den Versuchstagen am Campus Ost nahm das FZI ebenfalls mit Hilfe eines mobilen Sensorpostens die Szenarien auf. Dieser diente als Referenzsensorik, da durch den ausfahrbaren Mast die Verdeckungen auf ein Minimum reduziert werden konnten.

Die Aufzeichnungen wurden in beiden Fällen in dem ROS-spezifischen Datenformat als Rosbag abgespeichert. Es wurden Sensorrohdaten (Kamera, Lidar), GPS Position als auch die dynamischen Objekte aufgezeichnet.




Abbildung 10: Einsatzszenario mit Feuerwehr.

Am ersten Versuchstag wurde das Missachten von Verkehrsregeln an Kreuzungen erprobt. Dazu zählten unter anderem das Nehmen der Vorfahrt und das Überfahren von roten Ampeln. Die Szenarienauswahl am zweiten Versuchstag fokussierte sich auf die Verdeckung der Fahrzeuge bzw. der Passanten. Beteiligt waren Versuchsfahrzeuge unterschiedlicher Bauart der jeweiligen Projektpartner sowie Statisten und Hindernisse (Fußgänger, Fahrradfahrer, Motorrad, Anhängerfahrzeug, Sonderfahrzeug). Der Versuchstag am 19.10.22 zeichnete sich dadurch aus, dass neben Verdeckungen in Kreuzungsbereichen auch die Werksfeuerwehr des KIT mit vertreten war und verschiedene Einsatzszenarien mit der Feuerwehr aufgenommen werden konnten. Zusätzlich wurden Verdeckungen von vulnerablen Verkehrsteilnehmern (VRUs) ((Lastenfahrrad, Fahrrad, eBike, eScooter) in Kreuzungsbereichen nachgestellt. Der vierte Versuchstag wurde im öffentlichen Verkehrsraum (Stadtbereich Karlsruhe) durchgeführt. Insgesamt wurden fünf verschiedene

Örtlichkeiten, bspw. Oststadtkreisel, befahren. Der Fokus lag hierbei auf verdeckten und querenden Objekten (Passanten, Fahrradfahrer sowie Fahrzeuge jeglicher Art). Die Versuchsfahrten sowie die aufgezeichneten Daten dienen der Validierung der KISME-Algorithmen.

2.1.7 AP7 – Szenariengenerierung

Das FZI war in AP7 nicht beteiligt.

2.1.8 AP8 – Demonstratoren

In AP8 wurden die Ergebnisse des Projekts an realen Demonstratoren dargestellt. Dabei wurden einerseits die Demonstratoren zur Gewinnung von Testdaten als auch zur Validierung der in den anderen APs erarbeiteten KI-basierten Lösungen verwendet. Das FZI brachte die beiden Versuchsträger CoCar und CoCar NextGen für Validierungen in urbanen Kreuzungsbereichen ein.

Name des Demonstrators	PKW im urbanen Kreuzungsbereich
Verantwortlicher	FZI Forschungszentrum Informatik
Typ des Demonstrators	CoCar NextGen: PKW auf Basis eines Audi A6 Avant CoCar: SUV auf Basis eines Audi Q5
Einsatzort	Reales Testfeld öffentlich: Urbaner Kreuzungsbereich
Beschreibung des Demonstrators	<p>CoCar ist ein automatisiertes Fahrzeug auf Basis eines Audi Q5. Es besitzt umfangreiche Sensorik, wie Kamera und Lidarsensoren, um seine Umwelt korrekt wahrnehmen zu können. Dadurch ist es befähigt automatisiert am Straßenverkehr teilzunehmen. Da das selektive Datenlogging im Vordergrund steht, wurde CoCar in diesem Projekt als Mess- und Erprobungsfahrzeug für open-loop Komponenten hochautomatisierter Fahrfunktionen genutzt. Der Nachfolger CoCar NextGen besitzt ein deutlich umfangreicheres Sensorsetup, bestehend aus 12 Lidar-, 9 Kamera- und 2 Radarsensoren. CoCar NextGen wurde in diesem Projekt zur Sammlung von Daten genutzt.</p>
Beschreibung der durchgeführten Versuche	Im Rahmen des Projekts KISME wurden die Versuchsträger eingesetzt, um die entwickelten Algorithmen im Use-Case urbane Kreuzung hinsichtlich des effizienten Datenlogging zu erproben. Kreuzungen bieten durch die



Abbildung 11: CoCar



Abbildung 12: CoCar NextGen

	erhöhte Anzahl an verschiedenartigen Verkehrsteilnehmern eine ideale Testumgebung. des Szenarios.
Bezug zu den Arbeitszielen	CoCar wurde eingesetzt, um die entwickelten Systemarchitekturen (AP2) und Prädiktionsverfahren (AP3) an realen Szenarien zu erproben und zu verifizieren. CoCar NextGen stand erst gegen Ende der Projektlaufzeit zur Verfügung und wurde für die Datenakquise genutzt. Der Einsatz und Test der KI-Verfahren im realen Verkehr sind neben den Simulationsverfahren integrale Bestandteile des im Projekt durchgeführten Technologiehubs.
Metriken zur Bewertung der Demonstration	<ul style="list-style-type: none"> • Güte der Szenarienprädiktion in urbanen Bereichen mit einer erhöhten Anzahl an nichtmotorisierten Verkehrsteilnehmern (Abweichung zur Ground Truth) • Technologiereife des Onboard Systems, bestehend aus Trigger und Logger.

2.1.9 AP9 – Projektmanagement

Im Rahmen des Projektmanagements beteiligte sich das FZI an den monatlichen Jour Fixe Terminen, aus denen heraus das Projekt gesteuert wurde. Neben diesen virtuellen Absprachen fanden während dem Projekt sechs Konsortialtreffen statt. Des Weiteren übernahm das FZI die Leitung des Arbeitspakets AP3.

Typ	Datum	Ort
Konsortialtreffen – Kick Off	28.01.2021	Virtuell
Konsortialtreffen	28.09.2021	Heidelberg
Konsortialtreffen	28.06.2022	Bruchsal
Meilensteintreffen	18.10.2022	Karlsruhe
Konsortialtreffen	15.06.2023	Stuttgart
Abschlussveranstaltung	28.11.2023	Renningen

Da das Projekt ein hohes Maß an technischem Austausch zwischen den Projektpartnern erforderte, richtete das FZI ein projektspezifisches Gitlab ein, welches unter <https://gitlab.kissme-projekt.de/> erreichbar war. Ebenfalls hostete und wartete das FZI die Projektwebseite <https://kissme-projekt.de/>.

2.2 Zahlenmäßiger Nachweis

Position	Benennung im Antrag (AZK/AZA)	Verwendung
0837	Personalkosten	Durchführung Entwicklungen gemäß Projektplan, wissenschaftliche und studentische Hilfskräfte
0838	Dienstreisen	Teilnahmen an Projekttreffen, Integrationstreffen, Veranstaltungen und Konferenzen
0847	Abschreibung auf Vorhabenspezifische Anlagen	Abschreibungen für den HPC, die KI-Workstation, den FPGA und das Kamerasystem

2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Das Projekt war breit angelegt und benötigte Ressourcen aus Wissenschaft und Wirtschaft, insbesondere aus sehr unterschiedlichen Bereichen und Disziplinen wie KI-Algorithmen, formale Analyseverfahren, Echtzeitsysteme, Simulationssysteme, Umfeldsensorik, Fahrzeugintegration und Validierungsmethoden. Der Erarbeitung der geplanten Lösungen und Testumgebungen und dabei insbesondere die Kombination der notwendigen Technologien sowie deren Weiterentwicklung mit entsprechend hohen Entwicklungsaufwänden konnte von einem Industrie- oder Forschungspartner nicht alleine erarbeitet und umgesetzt werden, sondern es mussten verschiedene Unternehmen entlang der Wertschöpfungskette mit leistungsfähigen Forschungspartnern zusammenarbeiten. Nur in dem breit aufgestellten Gesamtkonsortium waren die Aufwände und technologischen Risiken handhabbar. Ohne öffentliche Förderung hätte das Vorhaben in dieser Art nicht durchgeführt werden können.

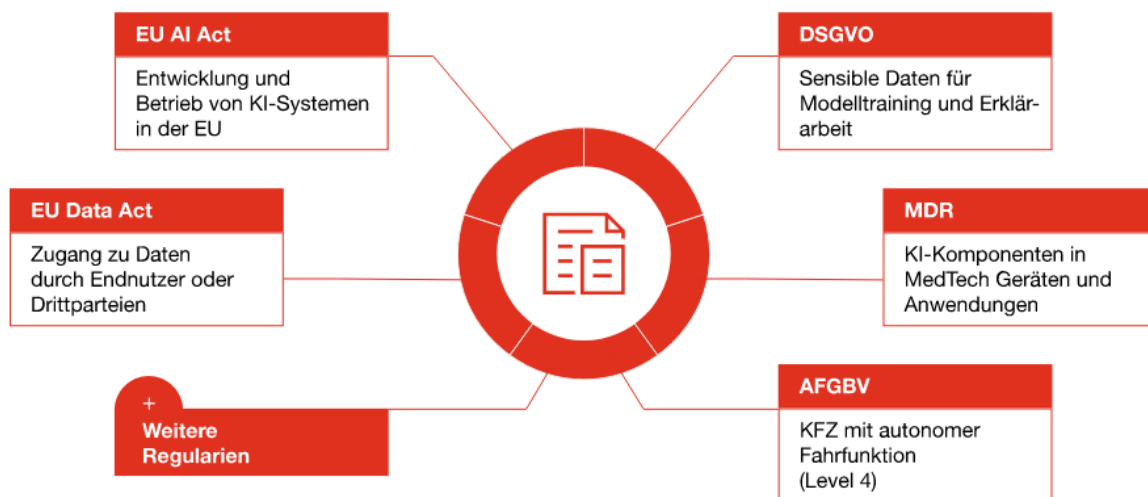
Das FZI Forschungszentrum Informatik brachte hierbei langjährige Erfahrung aus den Bereichen des automatisierten Fahrens und des Embedded System Designs, sowie Versuchsträger in das Projekt ein. Als gemeinnütziges Forschungszentrum mit starkem Anwendungsbezug bildet das FZI das Bindeglied von universitärer Forschung und der Industrie. Schwerpunkte des FZI bildeten die Konzeption von Verfahren zur Szenarienerkennung (AP1), die Erarbeitung der HW/SW KI-Basiskomponentenbibliothek (AP3), die Erforschung und Umsetzung von KI-basierten Umfelderkennungs- und Prädiktionsverfahren (AP4, AP5) sowie die Erprobung und Validierung mittels realer Demonstratoren (AP6, AP8). Das FZI als gemeinnützige Stiftung des bürgerlichen Rechts kann die benötigte Forschung, Weiterqualifizierung dringend benötigten Fachpersonals und somit den Transfer über Köpfe nicht ohne öffentliche Unterstützung leisten.

2.4 Voraussichtlicher Nutzen

Projektergebnis/ Inhalt	Nutzen/ Verwertung
Neuartige Verfahren zur Datenfusion und -verarbeitung	<p>Prädiktion: Das FZI entwickelte im Projekt das Modell HoliGraph – eine Trajektorienprädiktion auf Basis von Graph Neuronalen Netzen. Der Ansatz zeichnet sich durch einen umfangreichen Graphen aus, indem die vergangenen Zeitschritte aller Verkehrsteilnehmer als auch die Straßentopologie enthalten ist. Die Prädiktion bildet nicht nur den Grundstein, um risikoreiche Situationen frühzeitig erkennen zu können, sondern auch um die Bewegungsplanung eines automatisierten Fahrzeugs zu erleichtern. Das Modell wird in die weitere Forschung des FZIs eingebracht werden.</p> <p>FPGA: Das FZI hat im Rahmen des Projekts ein Software-Framework für einen FPGA-basierten Beschleuniger von Neuronalen Netze erweitert. Diese Software-Framework erlaubt das automatisierte Deployment von unterschiedlichen Netzwerkearchitekturen auf eine FPGA-basierte Lösung. Die Softwareschnittstelle wurde als OpenSource veröffentlicht und das zugehörige Paper wurde auf einer Konferenz präsentiert. Hieraus entstand ein Demonstrator, der im FZI House of Living Labs (HoLL) ausgestellt wird.</p>
Innovative Sensorik und Aktoriksysteme	<p>Das FZI hat im Rahmen des Projekts zum State-of-the-Art im Bereich Lidar-Perzeption beigetragen. Dabei wurde sowohl eine detaillierte Analyse zu den bestehenden Architekturen und Ansätzen und deren Laufzeiteigenschaften publiziert, als auch hat das FZI eigene Perzeptionsansätze entwickelt, die im FZI-Versuchsträger CoCar NextGen integriert wurden. Die hier gewonnen Erkenntnisse werden in zukünftige Forschungsprojekte des FZIs eingebracht.</p>
Versuchsträger Aufbau	<p>Während der Projektlaufzeit wurde das im Projekt entwickelte OnBoard System inklusive HPC in den FZI-Versuchsträger CoCar NextGen integriert. Im Projekt entwickelte Software-Funktionalitäten wie z.B. die FPGA-beschleunigten Neuronalen Netze sowie die KI-basierte Lidar-Perzeption wurden auf dem Abschlussevent im Versuchsträger vor Ort demonstriert. Der Versuchsträger bildet die Plattform für weitere Forschungstätigkeiten im Kontext des automatisierten Fahrens des FZIs.</p>
Wissenschaftliche Verwertung	<p>Die transparente und detaillierte Dokumentation durch Konferenzbeiträge sowie der wissenschaftliche Austausch ermöglichen den Transfer in die Industrie und die Forschungsgemeinschaft sowie den direkten Austausch, und hier insbesondere das Einholen von Rückmeldungen, mit der Forschungsgemeinschaft. Im Projekt getätigte Forschung fließt in die Dissertation von drei Mitarbeitenden ein und stärkt so den wissenschaftlichen Nachwuchs. Gleiches gilt für den Einsatz von wissenschaftlichen und studentischen Hilfskräften, welche in einem hochaktuellen Forschungsfeld mitwirken und lernen konnten. Die Erkenntnisse fließen außerdem in die Lehre am Karlsruher Institut für Technologie in Form von Praktika, Vorlesungen oder Seminaren mit ein.</p>

2.5 Fortschritte bei anderen Stellen

Seit Projektbeginn hat die Anwendung von KI, bspw. ChatGPT, in den unterschiedlichsten Domänen starke Fortschritte gemacht, die auch intensive gesellschaftliche Diskussionen angestoßen haben wie z.B. der EU AI Act. Dieser erwähnt explizit die automotive Domäne mit Fahrfunktionen Level 4-5 in festgelegten Betriebsbereichen (Abbildung 13).



Quelle: PwC „Europäische KI – Regulierung und ihre Umsetzung“

Abbildung 13: EU AI Act: Europäische KI-Regulierung und ihre Umsetzung

In industriellen Anwendungen konnte während der Laufzeit von Projekt KisSME die weltweit erste Zulassung einer Fahrfunktion Level 3 in Deutschland durchgeführt werden, weitere Zulassungen bzw. Erweiterungen der Operational Design Domain (ODD) sind in Arbeit.

Bisher sind Zulassungen von Fahrfunktionen Level 4 und 5, insbesondere von fahrerlosen Systemen im öffentlichen Straßenverkehr, noch nicht bekannt.

Im Forschungsprojekt VMMethoden [3] wurde der Einsatz von Kritikalitätsmetriken als wesentliche Grundlage zur Absicherung bzw. Zulassung von Fahrfunktionen für Level 4 und 5 vorangetrieben.

Auf dem Gebiet der Trajektorienprädiktion gab es während der Projektlaufzeit neue Arbeiten. Diese fokussieren vermehrt den Einsatz von Graph Neuronalen Netzen [26] - wie das im Projekt entwickelte HoliGraph Modell - als auch Transformer Architekturen [22].

Im Bereich der Lidar-Perzeption gab es während der Projektlaufzeit inkrementellen Fortschritt hinsichtlich der Entwicklung von neuen Architekturen und Trainingsmethoden [27] [28]. Insbesondere setzen viele State-of-the-Art Methoden auf Transformer-Architekturen und deren Skalierbarkeit auf größere Modelle mit mehr Parametern [29] [30]. Die Skalierung der Modellgröße kommt jedoch in der Praxis häufig auf Kosten von Rechenleistung und gefährdet somit der Echtzeitfähigkeit solcher Modelle, insbesondere bei wachsender Sensorauflösung. Somit ist deren Nutzbarkeit für die Integration ins Fahrzeug stark eingeschränkt.

Im Bereich der Objekterkennung durch Kamerabilder würden während der Projektlaufzeit neue State-of-the-Art Modelle veröffentlicht, z. B. Yolov10 [18]. Auch Transformer-Architekturen wurden

für Computer Vision evaluiert [31]. Aber diese neuen Modelle brauchen auch neue Hardwareunterstützung, um neue Art von Schichten effizient beschleunigen zu können.

2.6 Veröffentlichung der Ergebnisse

1. Peccia F. et al, "Integration of a systolic array based hardware accelerator into a DNN operator auto-tuning framework", CODAI 2022 Workshop on Compilers, Deployment, and Tooling for Edge AI
2. Grimm, D. et al.: "Holistic Graph-based Motion Prediction", 40th IEEE Conference on Robotics and Automation (ICRA 2023)
3. Uecker, M. et al.: "Analyzing Deep Learning Representations of Point Clouds for Real-Time In-Vehicle LiDAR Perception", NeurIPS 2022 Workshop on Machine Learning for Autonomous Driving
4. Häring, I et al.: "Framework for safety assessment of autonomous driving functions up to SAE level 5 by self-learning iteratively improving control loops between development, safety and field life cycle phases", 2021 IEEE 17th International Conference on Intelligent Computer Communication and Processing (ICCP)

3 Literaturverzeichnis

- [1] „Projekt PEGASUS: Etablierung von generell akzeptierten Gütekriterien, Werkzeugen und Methoden sowie Szenarien und Situationen zur Freigabe hochautomatisierter Fahrfunktionen,“ [Online]. Available: <https://www.pegasusprojekt.de>.
- [2] „Projekt SETLevel: Simulationsbasiertes Entwickeln und Testen von automatisierten Fahrzeugen,“ [Online]. Available: <https://setlevel.de> .
- [3] „Projekt VVMethoden: Verifikations- und Validierungsmethoden automatisierter Fahrzeuge Level 4 und 5,“ [Online]. Available: <https://www.vvm-projekt.de/>.
- [4] W. et al, „Multifunctional open-source simulation platform for development and functional validation of ADAS and automated driving“.
- [5] Y. Page et al., „A comprehensive and harmonized method for assessing the effectiveness of advanced driver assistance systems by virtual simulation: The P.E.A.R.S. initiative.,“ *24th International Technical Conference on the Enhanced Safety of Vehicles*.
- [6] H. Cui et al., „Multimodal Trajectory Predictions for Autonomous Driving using Deep Convolutional Networks,“ *2019 International Conference on Robotics and Automation (ICRA)*, 2019.
- [7] Y. Tang et al., „Multiple Futures Prediction. 33rd Conference on Neural Information Processing Systems,“ *NeurIPS*, 2019.

- [8] M. Lehmann et al., „Use of a criticality metric for assessment of critical traffic situations as part of SePIA,“ *Internationales Stuttgarter Symposium*, 2019.
- [9] P. Junietz, „Metrik zur Bewertung der Kritikalität von Verkehrssituationen und-szenarien,“ *11. Workshop Fahrerassistenzsysteme*.
- [10] J. Eggert et al., „Predictive risk estimation for intelligent adas functions,“ *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pp. 711-718, 2014.
- [11] C. Schmidt, „Hardware-in-the-Loop gestützte Entwicklungsplattform für Fahrerassistenzsysteme. Analyse und Generierung kritischer Verkehrsszenarien“.
- [12] T. Karras et al., „A style-based generator architecture for generative adversarial networks,“ *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2019.
- [13] C. Li et al., „Point cloud gan,“ *arXiv*, p. 1810.05795, 2018.
- [14] A. Sallab et al., „LiDAR sensor modeling and data augmentation with GANs for autonomous driving.,“ *arXiv*, p. 1905.07290, 2019.
- [15] C. Zhang et al., „Generative adversarial network for synthetic time series data generation in smart grids,“ *2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*, 2018.
- [16] „Projekt AVEAS: Absicherungsrelevante Verkehrssituationen erheben, analysieren, simulieren,“ [Online]. Available: <https://aveas.org/> .
- [17] M. Tan, „EfficientDet: Scalable and Efficient Object Detection,“ *arXiv*, p. 1911.09070, 2020.
- [18] A. Wang et al., „YOLOv10: Real-Time End-to-End Object Detection,“ *arXiv*, p. 2405.14458, 2024.
- [19] M. Liang et al., „Learning lane graph representations for motion forecasting,“ *arXiv preprint arXiv:2007.13732*, 2020.
- [20] Y. Yuan et al., „Agentformer: Agent-aware transformers for socio-temporal multi-agent forecasting,“ *arXiv preprint arXiv:2103.14023*, 2021.
- [21] X. Jia et al., „HDGT: Heterogeneous Driving Graph Transformer for Multi-Agent Trajectory Prediction via Scene Encoding,“ *arxiv*, p. 2205.09753, 2023.
- [22] Z. Zhou, L. Ye, J. Wang, K. Wu und K. Lu, „HiVT: Hierarchical Vector Transformer for Multi-Agent Motion Prediction,“ *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 8813-8823, 2022.
- [23] M. Liu et al., „LAformer: Trajectory Prediction for Autonomous Driving with Lane-Aware Scene Constraints,“ *arXiv*, p. 2302.13933, 2023.
- [24] L. Rowe et al., „FJMP: Factorized Joint Multi-Agent Motion Prediction over Learned Directed Acyclic Interaction Graphs,“ *arxiv*, p. 2211.16197, 2023.

- [25] W. Zhan, L. Sun, D. Wang, H. Shi, A. Clause, M. Naumann, J. Kummerle, 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,“ *arxiv*, p. 1910.03088, 2019.
- [26] A. Cui, S. Casas, K. Wong, S. Suo und R. Urtasun, „GoRela: Go Relative for Viewpoint-Invariant Motion Forecasting,“ *2023 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 7801-7807, 2023.
- [27] A. Xiao et al., „Polarmix: A general data augmentation technique for lidar point clouds,“ *Advances in Neural Information Processing Systems*, Bd. 35, pp. 11035--11048, 2022.
- [28] M. Hahner et al., „Quantifying data augmentation for lidar based 3d object detection,“ *arXiv*, p. 2004.01643, 2020.
- [29] X. Wu et al., „Point transformer v2: Grouped vector attention and partition-based pooling,“ *Advances in Neural Information Processing Systems*, Bd. 35, pp. 33330--33342, 2022.
- [30] X. Wu et al., „Point Transformer V3: Simpler Faster Stronger,“ *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 4840--4851, 2024.
- [31] S. Mehta et al., „MobileViT: Light-weight, General-purpose, and Mobile-friendly Vision Transformer,“ *arXiv*, p. 2110.02178, 2022.
- [32] „ECLIPSE OpenADx Working Group,“ [Online]. Available: <https://wiki.eclipse.org/OpenADx> .