KI WISSEN

Automotive AI Powered by Knowledge

Partnerspezifischer Schlussbericht

Berichtszeitraum: 01.01.2021 - 31.03.2024

AVL, AVL Software and Functions GmbH

Vorhabenbezeichnung	**KI Wissen - Entwicklung von Methoden für die Einbindung von Wissen in maschinelles Lernen**
Laufzeit des Vorhabens	01.01.2021-31.03.2024
Förderkennzeichen	19A20020D
Fälligkeitsdatum	01.10.2024
Erstellungsdatum	07.05.2024

Finanziert von der Europäischen Union
NextGenerationEU

Gefördert durch:
Bundesministerium für Wirtschaft und Klimaschutz
aufgrund eines Beschlusses des Deutschen Bundestages

Dokumenteninformation

Autoren

Dr. Federica Paolicelli – AVL Software and Functions GmbH

Reviewer

Matthias Meichel – AVL Software and Functions GmbH

Kontakt

Dr. Federica Paolicelli
AVL Software and Functions GmbH
Im Gewerbepark B29
93059 Regensburg
Deutschland

Phone: +49 94150272590
E-Mail: federica.paolicelli@avl.com

Revisionslog

Version	Datum	Kommentar	Autor	Partner
0.1	07.05.2024	Erster Entwurf	Federica Paolicelli	AVL
0.2	18.09.2024	Entwurf	Federica Paolicelli	AVL
1.0	07.05.2024	V1.0	Federica Paolicelli	AVL
1.1	19.02.2025	V1.1 – Ergänzung, Kapitel 3.5.3	Matthias Meichel	AVL

Inhaltsverzeichnis

1 Zusammenfassung **6**

2 Übersicht **8**

2.1 Aufgabenstellung 8

2.1.1 TP3 - Wissenskonformität 8

2.1.2 TP4 - Enabler, Integration und Demonstration 10

2.2 Voraussetzungen für das Vorhaben 12

2.3 Planung und Ablauf 13

2.4 Stand der Wissenschaft und Technik 14

2.5 Zusammenarbeit mit anderen Stellen 15

3 Eingehende Darstellung **16**

3.1 Erzielte Ergebnisse 16

3.1.1 TP3 16

3.1.2 TP4 20

3.2 3.2 Zahlenmäßiger Nachweis 29

3.2.1 TP3 29

3.2.2 TP4 29

3.3 Notwendigkeit der Förderung 31

3.4 Nutzen und Verwertbarkeit 32

3.5 Veröffentlichungen 32

3.5.1 Erfolgte Veröffentlichungen 32

3.5.2 Geplante Veröffentlichungen 32

3.5.3 Schutzrechtsanmeldungen 32

4 Literaturverzeichnis **33**

Abbildungsverzeichnis

Abbildung 1: Überblick über die Konformitätspipeline. 16

Abbildung 2: Gemeinsames Demonstrationskonzept. 21

Abbildung 3: Der Simulationsrahmen zeigt, wie das Ego-Fahrzeug einen Fahrspurwechsel einleitet, der eine durchgezogene Linie überquert, nachdem es ein stehendes Fahrzeug auf der Fahrspur erkannt hat (Szenario 3.2).....28

Abbildung 4: Vergleich der durchschnittlichen Genauigkeit zwischen dem Basismodell und dem angepassten Modell. Für die Daten der KI Wissen wurden fünf Szenen aus UC1 verwendet. 29

Abbildung 5: Von oben nach unten: Längsposition des erkannten vorderen Objekts, Beschleunigungsanforderung des Längsreglers, Beschleunigung des Ackermann-Reglers, auf Gas und Bremse normierte Werte. Fall mit Vorhersagen.....30

Abbildung 6: Von oben nach unten: Längsposition des erkannten vorderen Objekts, Beschleunigungsanforderung des Längsreglers, Beschleunigung des Ackermann-Reglers, auf Gas und Bremse normierte Werte. Fall ohne Vorhersagen. 31

Tabellenverzeichnis

Tabelle 1: Liste der Aufgaben in TP3, unterteilt nach Arbeitspaketen. 8

Tabelle 2: Liste der Aufgaben in TP4, unterteilt nach Arbeitspaketen. 10

1 Zusammenfassung

AVL leistete Beiträge zum Projekt KI Wissen in zwei der vier Teilprojekte (TPs), nämlich TP3, Wissenskonformität, und TP4, Enabler, Integration und Demonstration.

Das Ziel von TP3 war es, Fälle zu identifizieren, in denen KI-Entscheidungen von bestehendem Wissen abweichen. Dies wurde durch die Nutzung einer Reihe von Wissensquellen erreicht, darunter physikalisches und mathematisches Wissen (AP3.1 Physikalische Beziehungen), allgemeines Umweltwissen oder domänenspezifisches Fachwissen (AP3.2 Welt- und Expertenwissen), durch Lernen gewonnenes Wissen (AP3.3 Extrahierte Konzepte) und eine Kombination verschiedener Arten von Wissen (AP3.4 Kombination von Methoden). Die in diesem Teilprojekt entwickelten Methoden würden insbesondere in sicherheitskritischen Szenarien die Konformität mit der geforderten Wissensbasis gewährleisten.

AVL hat eine neue Methode entwickelt, um die Standort- und Zustandsattribute von erkannten Fußgängern zu kombinieren und eine Entscheidungsgrenze zu schaffen. Dieser aktualisierte Ansatz bietet größere Zuverlässigkeit und verbesserte Leistung in realen Anwendungen.

Wir testeten unseren Ansatz anhand eines realen Datensatzes (nuScenes [1]) und synthetischer Daten, die im Rahmen des KI Wissen-Projekts (AP4.4) erzeugt wurden. Für das Basismodell wählten wir einen LiDAR-basierten 3D-Detektor (PointPillars [2]) mit einem assoziationsbasierten Tracker von Hungarian [3]. Die Methode verwendet die folgenden Attribute zur Berechnung des Plausibilitätsscores:

- 3D-Detektorausgabe (Seitenverhältnis, Verdeckung, Konfidenzwert)
- Kartenebenen (Fahrspur, Parkzone, Kreuzung, Haltelinie und Gehweg)
- Zustandsraum (Geschwindigkeit, Beschleunigung, zurückgelegter Weg)

Die Ergebnisse zeigen eine bemerkenswerte Leistungssteigerung des kombinierten Konformitätsansatzes, wenn er auf den Basis-3D-Detektor angewendet wird. Wir erreichten eine Verbesserung von 6 % im nuScenes-Datensatz und eine Verbesserung von 6,5 % im synthetischen Datensatz.

Im Hinblick auf TP4 bestand das Hauptziel dieses Teilprojekts darin, eine Simulations- und Testumgebung einzurichten, um alle KI-basierten Komponenten und Methoden zu integrieren und zu bewerten, die von den Projektpartnern in anderen TPs entwickelt wurden.

TP4 bestand aus fünf Arbeitspaketen (APs): zwei konzeptionelle Arbeitspakete (AP4.1 Use Cases, Gütekriterien und Metriken; AP4.2 Gesamtsystemkonzept), gefolgt von einem Entwicklungs- und Integrationsarbeitspaket (AP4.3 Implementierung und Integration AD-Stack). Das vierte Arbeitspaket (AP4.4, Erzeugung und Bereitstellung Datensätze) war für die Sammlung von realen und synthetischen Datensätzen und die Erstellung von Simulationsszenarien verantwortlich. Das letzte Arbeitspaket (AP4.5, Evaluation und Demonstration) ermöglichte es den Projektpartnern, ihre neu entwickelten Komponenten in vollem Umfang zu demonstrieren.

AVL übernahm die Verantwortung für die Koordination und die Ergebnisse dieses TPs sowie für die Koordination und die Ergebnisse der Arbeitspakete 4.2 und 4.3.

Der AD-Stack wurde während des gesamten Projekts schrittweise entwickelt, wobei die Funktionalität in jeder Phase sichergestellt und gleichzeitig neue Funktionen und erweiterte Möglichkeiten auf der Grundlage der Anforderungen der Partner integriert wurden.

Das erste Demonstrationskonzept wurde in der ersten Projektphase entwickelt. Die Steuerungsmodule, die den Kern des AD-Stacks bilden, wurden in den CARLA [4] Simulator integriert und das gesamte System in einem vorläufigen Szenario getestet.

Der Aufbau des gemeinsamen Demonstrators war mit mehreren Herausforderungen verbunden. Eine der ersten Herausforderungen bestand darin, den Entwicklungsprozess so zu gestalten, dass eine schrittweise Integration möglich ist und nicht erst am Ende des Projekts. Mit diesem Ansatz sollte sichergestellt werden, dass die Integration ein integraler Bestandteil des Entwicklungsprozesses ist.

Ein weiterer wichtiger Aspekt war, dass die Implementierungsdetails der AD-Stack-Kernmodule, der Informationsfluss im Gesamtsystem und die Verarbeitung der Sensordaten von der Implementierung der neuen Komponenten getrennt werden konnten. Dies geschah mit dem Ziel, den Projektpartnern ein Maximum an Flexibilität bei der Gestaltung ihrer KI-basierten Module zu ermöglichen.

Im Laufe des Projekts wurden die Fähigkeiten des Demonstrators erweitert, um eine Reihe von Fahrszenarien abzudecken und den unterschiedlichen Bedürfnissen unserer Projektpartner gerecht zu werden.

Eines der Hauptergebnisse dieses Teilprojekts war die Erstellung und Bereitstellung von Datensätzen. AVL stellte den Projektpartnern einen Datensatz mit insgesamt 57 Sequenzen zur Verfügung. Darüber hinaus wurden die Datensätze mit Kartendaten aus ASAM OpenStreetMap angereichert und anhand der GPS-Koordinaten der Aufnahmefahrzeuge in das OpenDRIVE-Format konvertiert. Darüber hinaus konnte das TP4-Demonstrationssystem genutzt werden, um synthetische Daten zu generieren, die für weitere Tests und Evaluierungen der neu entwickelten Komponenten von Vorteil sind.

Im Laufe des Projekts sahen sich die PMT und der Lenkungsausschuss mit einer Reihe von Risiken konfrontiert, die identifiziert worden waren. Zu Beginn herrschte eine gewisse Unklarheit über die Zuständigkeit der VHB für die Szenarienerstellung. Seit dem zweiten Jahr des Projekts bietet AVL den Partnern kostenlose Lizenzen für den AVL Scenario Designer an, ein von der AVL-Zentrale entwickeltes Tool.

Während der Integrationsphase gab es einige Verzögerungen aufgrund von Koordinationsproblemen zwischen den notwendigen Arbeiten im Demonstrator und der Integration der Komponenten durch die Partner. Den Partnern wurde keine klare Frist für die Integration der neu entwickelten Komponenten in den Demonstrator gesetzt, was zu einigen Schwierigkeiten bei der Einhaltung des gesamten Projektzeitplans führte. Die Projektverlängerung um drei Monate ermöglichte jedoch den erfolgreichen Abschluss aller Aktivitäten.

2 Übersicht

Dieses Kapitel gibt einen umfassenden Überblick über die Aufgaben, die AVL im Rahmen der beiden Teilprojekte, an denen wir teilgenommen haben, nämlich TP3 und TP4, übertragen wurden. Der Bericht basiert auf der Aufgabendefinition, die in der ursprünglichen Projektbeschreibung beschrieben ist.

2.1 Aufgabenstellung

2.1.1 TP3 - Wissenskonformität

Teilprojekt 3 (TP3) konzentrierte sich auf die Identifizierung von Inkonsistenzen zwischen dem Output von KI-Komponenten und formalisiertem Wissen mit dem Ziel, die Robustheit und Betriebssicherheit von KI-Komponenten zu erhöhen. Zu diesem Zweck wurden verschiedene Wissensquellen integriert, darunter physikalisches und mathematisches Wissen (AP3.1), Welt- und Expertenwissen (AP3.2), extrahiertes Wissen (AP3.3) und kombiniertes Wissen (AP3.4).

In TP3 konzentrierte sich die AVL auf der Grundlage der Ergebnisse von TP1 und TP2 auf den ersten Anwendungsfall (UC1) und implementierte Methoden mit dem Ziel, die Robustheit eines Wahrnehmungsmoduls für die Fußgängererkennung und -verfolgung zu verbessern. Der entwickelte Ansatz wurde in die Simulationsumgebung integriert und getestet, die in TP4 eingerichtet wurde, nämlich den AD Stack.

Was die einzelnen Arbeitspakete betrifft, so wurden in AP3.1 die Methoden analysiert und neue Konzepte entwickelt. In AP3.2 wurden Regeln entwickelt und die Architektur des tiefen neuronalen Netzes (DNN) definiert. In AP3.3 wurden die implementierten Konzepte evaluiert und ihre Leistung verglichen. Schließlich wurde in AP3.4 eine Plausibilitätsprüfung des Outputs entwickelt und die Methode in den AD Stack integriert.

Die nachstehende Tabelle enthält zusätzliche Informationen zu den Besonderheiten der einzelnen Aufgaben und dem zugewiesenen Aufwand, ausgedrückt in Personenmonaten (PM).

Tabelle 1: Liste der Aufgaben in TP3, unterteilt nach Arbeitspaketen.

TP3	
AP3.1 Physikalische Beziehungen	Aufwand: 10 PM
Erforschung des Stands der Technik und Identifizierung vielversprechender Deep-Learning-Architekturen, die für die Erkennung und Verfolgung von Fußgängern im Anwendungsfall 1 geeignet sind (E3.1.1, E3.1.2, E3.1.3) • Kriterien formulieren und bewerten • Kriterien formulieren, um die mathematischen und physikalischen Inkonsistenzen aufzudecken • Bewertung der oben formulierten Kriterien • Konzeptentwicklung und Dokumentation, um die oben formulierten Kriterien umzusetzen	
AP3.2 Welt- und Expertenwissen	Aufwand: 10 PM
Identifizierung der Quellen von Welt- und Expertenwissen (E3.2.1) • Identifizierung der Quellen von Welt- und Expertenwissen zur Erkennung von Fußgängern in Use Case 1 **Extraktion und Dokumentation der physikalischen/mathematischen Regeln (E3.2.2)**	

TP3

- Extraktion und Dokumentation der physikalischen/mathematischen Regeln, die zur Verbesserung der Robustheit der Fußgängererkennung verwendet werden können

Methodenentwicklung (E3.2.3)

- Methodenentwicklung zur Anwendung der oben identifizierten Regeln und Kenntnisse

Definition der DNN-Architektur und der Schnittstellen (E3.2.4)

- Definition der DNN-Architektur und der Schnittstellen unter Berücksichtigung der oben genannten Regeln und Kenntnisse

AP3.3 Extrahierte Konzepte Aufwand: 8 PM

Formulierung einer Plausibilitätschecks (E3.3.1)

Formulierung einer Plausibilitätschecks, der für die Fußgänger-Erkennung und -Verfolgung geeignet ist

Analyse der Systemarchitektur (E3.3.2)

- Untersuchung der Systemarchitektur
- Untersuchung der DNN-Architektur, insbesondere hybrider Architekturen (z. B. CNNs und rekurrente neuronale Netze) für Fußgänger-Erkennung und -Verfolgung

Verständnis des innen Mechanismus eines DNNs (E3.3.2)

- Verständnis des innen Mechanismus eines neuronalen Netzwerks mit verschieden Techniken, wie z.B. Features Maps
- Dokumentation des oben genannten/untersuchten Mechanismus

Vergleich zwischen Deep-Learning-Modellen und klassischen Methoden (E3.3.2)

- Entwicklung einer klassischen Methode für die Fußgängerverfolgung
- Plausibilitäts- und Vergleichsprüfung der Ergebnisse zwischen Deep-Learning-Modellen und klassischen Methoden

Zuverlässigkeit erhöhen durch Sensorfusion (E3.3.2)

- Erhöhung der Zuverlässigkeit durch Fusion der nachbewerteten Kameradetektionen mit z.B. LiDAR-Daten

AP3.4 Kombination von Methoden Aufwand: 8 PM

Implementierung eines Plausibilitätschecks des Outputs (E3.4.1)

- Implementierung eines Plausibilitätschecks des Outputs, der für den Use Case 1 und die schon definierte Architektur zusammenpasst. Dieser Plausibilitätscheck könnte auf der Einhaltung der bereits definierten physikalischen Beschränkungen basiert sein
- Quantitative Bewertung dieser Umsetzung

Integration der entwickelten Methoden im AD-Stack (E3.4.2)

- Integration der entwickelten Methoden in den AD-Stack, der in AP4.2/ AP4.3 geliefert wird
- Testen der integrierten Methoden anhand von Simulationsdaten unter dem definierten Use Case 1
- Aktualisierung der entwickelten Methode basierend auf den Testergebnisse, die in der TP4 entwickelter Simulationsumgebung generiert werden können

Testanalyse und Berichte (E3.4.3)

- Testanalyse und Bericht basierend auf den Testergebnisse in E3.4.2

2.1.2 TP4 - Enabler, Integration und Demonstration

Das Teilprojekt 4 (TP4) verfolgte ein anderes Ziel als die anderen Teilprojekte. Anstatt externe Wissensquellen in KI-basierte Komponenten zu integrieren, diente es der Unterstützung der anderen TPs.

Hauptziel war die Schaffung einer Infrastruktur für die Integration der neu entwickelten Komponenten und die Einrichtung eines Demonstrators für die Erprobung und Validierung dieser Komponenten, sowohl einzeln als auch in einem geschlossenen Kreislaufsystem im Rahmen einer AD-Gesamtfahrzeugarchitektur.

Die TP wurde in Übereinstimmung mit den Spezifikationen entwickelt, die in fünf verschiedenen Arbeitspaketen beschrieben wurden. Die Anwendungsfälle und Bewertungsmaßstäbe des Projekts wurden in AP4.1 definiert. In AP4.2 wurde das Gesamtsystemkonzept für den Demonstrator beschrieben. In AP4.3 wurde der Demonstrator vollständig entwickelt, und die neu entwickelten Komponenten aus TP1-3 wurden integriert. Ziel von AP4.4 war die Erstellung von Datensätzen, die sowohl synthetische als auch reale Daten umfassen. In AP4.5 schließlich konzentrierten sich die Projektaktivitäten auf die Validierung und Demonstration der neu entwickelten Komponenten.

Die AVL spielte in diesem Teilprojekt eine wichtige Rolle, da sie die Hauptverantwortung für die Entwicklung des gemeinsamen Demonstrators trug und gleichzeitig eine Führungsposition für das gesamte TP und zwei Arbeitspakete, nämlich AP4.2 und AP4.3, übernahm.

Die nachstehende Tabelle enthält weitere Einzelheiten zu den Aufgaben der AVL und dem zugewiesenen Aufwand, ausgedrückt in Personenmonaten (PM).

Tabelle 2: Liste der Aufgaben in TP4, unterteilt nach Arbeitspaketen.

TP4	
AP4.1 Use Cases, Gütekriterien und Metriken	Aufwand: 12 PM
Ausdefinition Use Cases, Metrikkatalog, "kleine" Version für mindestens 2 Use Cases (E4.1.1) • Übertragung von Anwendungsfällen in eine formale Darstellung • Definition der Grenzen des Bereichs, der von den Anwendungsfällen abgedeckt werden soll • Abgleich der definierten KPIs mit dem definierten Anwendungsfallumfang	
AP4.2 Gesamtsystemkonzept	Aufwand: 12 PM
Anforderungskatalog und Architekturdefinition (E4.2.1, E4.2.3, E4.2.4) • Aufnahme der bisherigen Ergebnisse des Anforderungskatalogs und Erweiterung um Integrationsdetails • Definition einer allgemeinen Architektur zur Gewährleistung größtmöglicher Flexibilität und Wiederverwendbarkeit **Funktionale Definition von AD-Stack und Umgebung (E4.2.2, E4.2.3)** • Definition der Grenzen des Bereichs, der von den Anwendungsfällen abgedeckt werden soll • Analyse der vorhandenen Funktionalitäten der einzelnen Komponenten • Entwicklung und Anpassung der Stack-Architektur Iterative Anpassung der Schnittstellenarchitektur	
AP4.3 Implementierung und Integration AD-Stack	Aufwand: 62 PM

TP4

Konzeptionelle und Koordinations-Arbeiten zur Schaffung einer Basis für Continuous Integration (E4.3.1)

- Dokumentation aller bisherigen Anforderungen an den AD-Stack
- Koordinierung der Schnittstellendokumentation der einzelnen Teilkomponenten
- Vorbereitung der Dokumentation der bestehenden Funktionalitäten für die Stack-Architektur und -Integration
- Planung und Verfolgung der einzelnen Integrationsschritte innerhalb des kontinuierlichen Integrationsprozesses

Integration der bisherigen Ergebnisse in AD-Stack (E4.3.1)

- Vorbereiten der Umgebungsdaten für den AD-Stack in der verwendeten Simulationsumgebung
- Definition der Architektur der einzelnen Komponenten des Gesamtsystems des AD-Stacks
- Feinabstimmung der Architektur des AD-Stacks auf alle zuvor entwickelten Funktionalitäten
- Sicherstellung der Ausführbarkeit einer ausführbaren Integration

Vorbereitung der Integration (E4.3.3)

- Auswahl der einzelnen Komponenten für die entsprechenden Integrationsstufen
- Definition der Architektur und der Schnittstellen der einzelnen Komponenten des AD-Stacks
- Definition der Architektur und der Schnittstellen des gesamten AD-Stack-Systems
- Definition der Schnittstellen zur Anbindung der entwickelten Methoden
- Konzeption der Schnittstellenfunktionalitäten des AD-Stacks innerhalb der Simulationsumgebung
- Vorbereiten der Umgebungsdaten für den AD-Stack in der verwendeten Simulationsumgebung
- Aufbau der einzelnen Funktionskomponenten des Stacks
- Anpassung der einzelnen Funktionalitäten der Simulationsumgebung an die Architektur des Stacks
- Bereitstellung von Schnittstellen innerhalb der Simulationsumgebung
- Test der neu bereitgestellten Simulationsschnittstellen auf allgemeine Funktionalität

Integration des Stacks (E4.3.3)

- Zusammenführung der einzelnen Komponenten des Stacks
- Schnittstellentest aller Komponenten innerhalb des integrierten Stacks
- Integration des AD-Stacks in die gesamte Simulationsumgebung
- Initiale Durchführung erster Integrationstests um eine erfolgreiche Integration des AD-Stacks in die Simulationsumgebung zu gewährleisten

AP4.4 Erzeugung und Bereitstellung Datensätzen Aufwand: 24 PM

Konzeptionelle und Koordinations-Arbeiten im Hinblick auf die Erfassung benötigter Daten (E4.4.1)

- Koordinierung der Kalibrierung des Messsystems auf die Ergebnisse der vorangegangenen Arbeitspakete
- Diskussion über die Umsetzung der Anwendungsfälle in realen Aufzeichnungsreisen
- Definition der Schnittstellen für die Datenintegration zur Überführung der aufgenommenen Szenarien und späteren Verwendung in der Simulation

Kalibration und Inbetriebnahme des Messsystems (E4.4.1)

- Intrinsische Kalibration der einzelnen Sensoren des Messystems incl. Anpassung an Testumgebung
- Sensor-zu-Sensor Kalibration im simulatorischen Systemverbund
- Physische Kalibration des Messsystems im Gesamtsystemverbund

TP4

Testdatengeneration (E4.4.2)

- Strukturierung der einzelnen Use-Cases nach den verkehrstechnischen Gegebenheiten
- Planung der Aufnahme-Fahrten für die einzelnen Szenarien nach größtmöglicher Effizienz
- Durchführung der Testfahrten zum Einfahren aller notwendigen Testdaten (gemäß den definierten Use Cases)
- Extraktion und Aufbereitung der eingehenden Daten
- Überführen der Daten in ein für die Simulation geeignetes Format

AP4.5 Evaluation und Demonstration Aufwand: 12 PM

Konzeptionelle und Koordinations-Arbeiten im Zusammenhang mit der Demonstration (E4.5.1)

- Koordination der Integration in Abstimmung mit allen beteiligten Parteien
- Definition des Demonstrationsumfangs des AD-Stacks innerhalb der Simulationsumgebung
- Koordinierung des jeweiligen Integrationsumfangs für sämtliche SW-Updates

Simulation des AD-Stacks (E4.5.2)

- Vorbereitung der Simulationsumgebung zur Erweiterung um AD-Stack
- Integration des AD-Stacks in die simulatorische Gesamtumgebung
- Iterative Durchführung von Integrationstests (für jede SW-Version), um eine erfolgreiche Integration des AD-Stacks in die Simulationsumgebung zu gewährleisten
- Demonstration des AD-Stacks in der Simulationsumgebung
- Validierung und Verifizierung des integrierten AD-Stacks in der Simulation

2.2 Voraussetzungen für das Vorhaben

Das Projekt KI Wissen, Teil der KI Familie, wurde von der VDA Leitinitiative für autonomes und vernetztes Fahren initiiert und entwickelt. Das vom Bundesministerium für Wirtschaft und Klimaschutz geförderte Projekt hatte zum Ziel, Wissen in KI-basierte Prozesse für autonome Fahrzeuge zu integrieren und die Herausforderungen der Datenabhängigkeit durch die Kombination von datengetriebenen Methoden mit wissensbasierten Ansätzen zu adressieren. Diese Integration soll die Stabilität, Effizienz und Qualität von KI-Funktionen im autonomen Fahren erhöhen.

Das Projekt wurde in Zusammenarbeit mit einem breit gefächerten Konsortium von Partnern entwickelt, von denen jeder sein Fachwissen zu verschiedenen Aspekten des Projekts beisteuerte. Das Projekt profitierte von den Beiträgen zahlreicher Unternehmen, die wesentliche Komponenten und Technologien für die Entwicklung und Integration von KI-Systemen in autonomen Fahrzeugen bereitstellten. Organisationen, die sich auf KI und maschinelle Lerntechnologien spezialisiert haben, leisteten wertvolle Beiträge in Form von fortschrittlichen Methoden und Werkzeugen zur Wissensintegration und -extraktion. Forschungseinrichtungen betrieben Grundlagenforschung zu KI, Wissensrepräsentation und autonomen Fahrtechnologien, während akademische Partner theoretische Erkenntnisse lieferten und Untersuchungen zur Unterstützung der Projektziele durchführten. Die folgenden Projektpartner bildeten das Konsortium:

- Zulieferer: Continental, Bosch, Valeo.

- Technologie-Anbieter: Alexander Thamm, AVL, BTC, Capgemini, e:fs.
- Forschungseinrichtungen: DFKI, DLR, Fortiss, Fraunhofer, FZI.
- Universitäten: Universität des Saarlandes.
- Föderale Forschungsinstitutionen: Bast.
- Externe Partner: EICT.

Die Zusammenarbeit zwischen diesen Partnern war durch wissenschaftlichen Austausch und Kooperation gekennzeichnet. Dieser kollaborative Rahmen sorgte dafür, dass das Projekt von einem breiten Spektrum an Fachwissen und Perspektiven profitieren konnte, was Innovation und Fortschritt auf dem Gebiet des autonomen Fahrens förderte.

2.3 Planung und Ablauf

In diesem Abschnitt werden die Planung und die Verfahren beschrieben, die während des gesamten Projekts durchgeführt wurden und die eine Reihe von kritischen Schritten umfassten, um ein strukturiertes und effizientes Vorgehen zu gewährleisten.

Das Projekt wurde in vier Hauptteilprojekte unterteilt, nämlich Wissensintegration (TP1), Wissensextraktion (TP2), Wissenskonformität (TP3) und Enabler, Integration und Demonstration (TP4). Jedem Teilprojekt wurden spezifische Aufgaben und Ergebnisse zugewiesen.

1. Integration von Wissen:

   Das für die Verkehrssituation relevante Wissen wurde identifiziert und systematisiert. Dazu wurden Daten aus einer Vielzahl von Quellen gesammelt, darunter Verkehrsvorschriften, Straßenzustände und Fahrverhalten. Das ermittelte Wissen wurde in das Training und die Entwicklung von neuen KI-Architekturen integriert. Dieser Schritt wurde mit dem Ziel unternommen, KI-Systeme zu schaffen, die in der Lage sind, sowohl Daten als auch strukturiertes Wissen zur Entscheidungsfindung zu nutzen.

2. Extraktion von Wissen:

   Es wurden Methoden zur Extraktion von Wissen entwickelt und angepasst. Dazu gehörten Techniken für die Extraktion von Konzepten aus Modellen und die Erzeugung strukturierter Ergebnisse. Die entwickelten Methoden wurden in KI-Systeme implementiert, so dass diese sowohl aus Daten als auch aus expliziten Wissensrepräsentationen lernen können.

3. Wissen Konformität:

   Es wurden Methoden zur Unterstützung der Plausibilitätsprüfung und Validierung von KI-Funktionen entwickelt. Dadurch wurde sichergestellt, dass die KI-Entscheidungen mit dem formalisierten Wissen übereinstimmen, was die Zuverlässigkeit und Sicherheit erhöht. Die KI-Funktionen wurden anhand einer Reihe von vordefinierten Kriterien validiert, um ihre Konformität mit dem integrierten Wissen sicherzustellen.

4. Enabler, Integration und Demonstration:

Die im Projekt entwickelten Funktionen, Komponenten und Methoden wurden mit einem autonomen Fahrsimulator evaluiert. Dabei wurden die KI-Systeme in verschiedenen Verkehrsszenarien auf ihre Leistungsfähigkeit hin untersucht. Die Wirksamkeit der integrierten wissensbasierten Ansätze wurde durch die Analyse von praxisnahen Fahrszenarien nachgewiesen. Dies diente der Validierung der Projektergebnisse und der Demonstration des Potenzials der entwickelten Methoden.

Für jedes Teilprojekt wurden ein Anfangs- und ein Enddatum festgelegt, sowie eine Liste der zugehörigen Arbeitspakete, eine Reihe von Leistungen und Punkte, an denen über die Arbeitsergebnisse berichtet werden sollte. Die so festgelegten Fristen waren ein wesentlicher Bestandteil eines umfassenden Überwachungssystems, das die rechtzeitige Erfüllung der Aufgaben der einzelnen Arbeitspakete gewährleisten sollte. Die Berichte enthielten Informationen über anstehende Aktivitäten sowie über mögliche Risiken und Probleme. Jeder Aufgabe wurde ein bestimmter Zeitraum zugewiesen, und es wurden Abhängigkeiten ermittelt, um die Reihenfolge der Aktivitäten festzulegen. Anhand dieser Aufschlüsselung wurde ein detaillierter Zeitplan für das Projekt erstellt. Der Zeitplan des Projekts wurde genau überwacht, wobei sich herausstellte, dass eine Anpassung gegen Ende des Projekts aufgrund unvorhergesehener Herausforderungen erforderlich war. Die Ressourcen, einschließlich der finanziellen und personellen Mittel sowie der erforderlichen technischen Hilfsmittel, wurden jeder Aufgabe entsprechend ihren Anforderungen zugewiesen.

2.4 Stand der Wissenschaft und Technik

Die Weiterentwicklung der künstlichen Intelligenz (KI) für autonome Fahrzeuge wurde in der Vergangenheit durch die Anhäufung von Daten vorangetrieben, was die Verfügbarkeit umfangreicher Daten für Trainings- und Validierungszwecke erforderte. Dieser datenzentrierte Ansatz ist ressourcenintensiv und kostspielig und führt häufig zu Blackbox-Modellen, deren Entscheidungsprozesse nicht ohne weiteres interpretierbar sind. Die bisherige Forschung hat sich vor allem auf die Optimierung der Datenanforderungen für das Training und die Validierung von KI konzentriert, um die oben genannten Herausforderungen zu bewältigen.

Mit dem Projekt KI Wissen wurde ein neuartiger Ansatz eingeführt, nämlich die Integration von vorhandenem Wissen in datengesteuerte KI-Funktionen. Ziel dieser Integration war es, ein umfassendes Ökosystem zu schaffen, das das Training von KI-Funktionen erleichtert und ihre Funktionsweise sichert. Das Projekt zielt darauf ab, die Abhängigkeit von umfangreichen Datensätzen zu verringern und die Erklärbarkeit von KI-Modellen durch die Einbeziehung von Wissen aus verschiedenen Bereichen zu verbessern.

Eine bemerkenswerte Innovation, die unser Team für dieses Projekt vorgeschlagen hat, ist die Integration von Objektstandort und erkannten Zustandsraumattributen, um die Entscheidungsgrenzen abzugrenzen. Diese Methode erhöht die Zuverlässigkeit von KI-Erkennungen und verbessert die Leistung in realen Anwendungen. Durch eine bessere Anpassung der KI-Ergebnisse an reale Szenarien wurden im Rahmen des Projekts die inhärenten Anpassungsprobleme herkömmlicher Black-Box-Modelle behoben.

2.5 Zusammenarbeit mit anderen Stellen

Während der Durchführung des KI-Wissen-Projekts haben wir engen Kontakt zu allen Konsortialpartnern und zusätzlich zu den folgenden Unternehmen und Projekten gehalten:

- **AVL List GmbH**

  Die AVL List GmbH mit Sitz in Graz bot allen Partnern der KI Wissen für die Dauer des Projekts kostenlose Lizenzen für den selbst entwickelten AVL Scenario Designer™ (avl.com/avl-scenario-designer) an. Das Tool hat es uns und zahlreichen Partnern ermöglicht, Szenarien zu entwickeln, die anschließend für Simulationen im Projektdemonstrator verwendet wurden.

- **Capgemini Outsourcing Dienstleistungen GmbH**

  Capgemini Outsourcing (capgemini.com) war das Drittunternehmen, das die öffentliche Ausschreibung im Rahmen der GUA3 gewann. Sie lieferte Datenkennzeichnungsdienste zur Unterstützung dieses Projekts. Das Unternehmen bot die **Anonymisierung** aller sichtbaren Fahrzeugkennzeichen und Gesichter in allen Frames, die Beschriftung aller sichtbaren Objekte in den Lidar-Frames unter Verwendung von 2D- und 3D-Quadern und die semantische Instanzsegmentierung aller Objekte gemäß den im Projekt definierten Spezifikationen.

- KI-Daten-Tooling

  KI Data Tooling (ki-datatooling.de) ist eines der Projekte der KI Familie. Es konzentrierte sich speziell auf Daten als Grundlage für KI-basierte und maschinelle Lerntechnologien. So konnten wir das Datenformat für die im Rahmen von KI Wissen generierten bzw. erfassten Daten auf Basis der im KI Data Tooling gewonnenen Erfahrungen definieren.

3 Eingehende Darstellung

Dieses Kapitel enthält eine detaillierte Beschreibung der Ergebnisse, die die AVL im Rahmen des KI Wissen-Projekts in den Teilprojekten 3 und 4 erzielt hat.

3.1 Erzielte Ergebnisse

3.1.1 TP3

Das Ziel von TP3 war es, mit Hilfe von formalisiertem Wissen Inkonsistenzen zwischen der Ausgabe einer KI-Komponente und der realen Welt zu erkennen und so die Leistung der Wahrnehmungsfunktion zu verbessern. Das Team von AVL hat an einer Methode zur Objekterkennung gearbeitet, mit besonderem Schwerpunkt auf Fußgängern. Die neu entwickelte Komponente basiert auf der Idee, den Standort des detektierten Fußgängers mit dessen detektierten Zustandsraumattributen (Geschwindigkeit, Beschleunigung, zurückgelegte Strecke) zu kombinieren, um eine Entscheidungsgrenze zu definieren. Es hat sich gezeigt, dass die aktualisierten Erkennungen zuverlässiger sind und die Erkennungsleistung in realen Anwendungen verbessern.

Für das Basismodell wurde ein LiDAR-basierter 3D-Detektor (PointPillars) mit einem auf ungarischen Assoziationen basierenden Tracker gewählt. Die Methode verwendet die folgenden Attribute zur Berechnung der Plausibilitätsbewertung (Abbildung 1):

- 3D-Detektorausgabe (Seitenverhältnis, Verdeckung, Konfidenzwert)
- Kartenebenen (Fahrspur, Parkzone, Kreuzung, Haltelinie und Gehweg)
- Zustandsraum (Geschwindigkeit, Beschleunigung, zurückgelegter Weg)

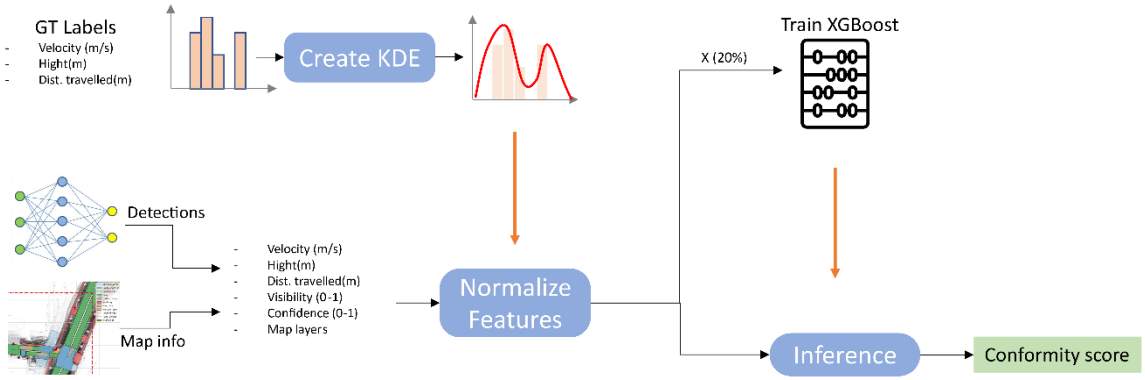

Abbildung 1: Überblick über die Konformitätspipeline.

Die Entwicklung begann mit der Integration von physikalischem Wissen. Um die physikalische Konformität zu gewährleisten, schlug AVL vor, physikalische Konzepte als mathematische Einschränkungen zu verwenden, um die harten und weichen Grenzen für die Erkennungen und Vorhersagen des KI-Modells zu definieren.

In der Anfangsphase des Projekts hat die AVL mit den Arbeitspaketen 3.1 und 3.2 begonnen.

In AP3.1 konzentrierte sich die AVL auf die Erforschung von State-of-the-Art-Methoden und die Identifizierung vielversprechender Deep-Learning-Architekturen, die für die Erkennung und Verfolgung von Fußgängern geeignet sind, um sie auf Anwendungsfall 1 anzuwenden: Fußgängererkennung bei Sichtbehinderung. Die AVL investierte den größten Teil ihrer Arbeit in die Erforschung von Methoden und Bewertungskriterien für die Leistung der Methoden in den ersten Monaten des Projekts, während sie die konzeptionelle Hauptarbeit für die zweite Jahreshälfte plante.

In Bezug auf AP3.2 arbeitete AVL an der Identifizierung von Welt- und Expertenwissensquellen für die Erkennung von Fußgängern in Anwendungsfall 1, dem Konzept für die Extraktion physikalischer und mathematischer Regeln sowie der Definition der DNN-Architektur und der Schnittstellen. Auch in diesem Fall investierte AVL in der ersten Jahreshälfte den größten Teil der Anstrengungen in die Erforschung verschiedener Wissensquellen, während die Hauptentwicklungsarbeit für die zweite Jahreshälfte geplant war.

In der zweiten Hälfte des Jahres 2021 leistete die AVL wesentliche Beiträge zu den Arbeitspaketen 3.1 und 3.2.

In AP3.1 konzentrierte sich die AVL auf die Entwicklung eines Fußgängerbewegungsmodells für prädiktive Modellierung und Anomalieerkennung. Ziel war es, ein System zu entwickeln, das unplausible Zustände eines erkannten Fußgängers aufgrund physischer Einschränkungen erkennen kann.

Bei der prädiktiven Modellierung wurden alle Erkennungen von Fußgängern an die Höhe und Breite der Bounding Boxes angepasst. Zu diesem Zweck wurde eine Gaußsche Kurve entwickelt, die das Verhältnis von Körperhöhe und -breite für Fußgänger unterschiedlichen Alters, Geschlechts und Körperkategorien (z. B. schlank, gesund, fettleibig) berücksichtigt, wie in der Literatur dokumentiert [5]. Anhand des Seitenverhältnisses, d. h. des Verhältnisses von Höhe zu Breite der Bounding Box, wurde überprüft, ob es sich bei den erkannten Personen um Fußgänger handelte oder nicht. In der zweiten Phase wurden Bewegungsgleichungen verwendet, um den zukünftigen Zustand der Fußgänger zu berechnen und die Ergebnisse des KI-Modells unter Berücksichtigung von Messfehlern zu validieren.

Darüber hinaus war die Erstellung eines statistischen Trajektorienmodells geplant, um Anomalien in den Trajektorien von Fußgängern innerhalb eines bestimmten Szenarios zu identifizieren. Dieses statistische Trajektorienmodell würde Clustering-Algorithmen und aufgezeichnete Trajektorendaten nutzen, um die Trajektorie eines bestimmten Fußgängers zu überprüfen.

In AP3.2 konzentrierte sich die AVL auf die Quellen für globales und Expertenwissen, nämlich räumliches Wissen (geografische und visuelle Konzepte) und Verkehrswissen (soziale und rechtliche Normen), um die Ergebnisse des KI-Modells für die Fußgängererkennung und -verfolgung in UC1 zu validieren. Darüber hinaus wollte die AVL HD-Karten und den Autoencoder nutzen, um die Ergebnisse des KI-Modells zu untermauern.

HD-Karten wurden verwendet, um die statische Umgebung des Ego-Fahrzeugs zu extrahieren und alle Erkennungen gemäß den normalen Fahrkenntnissen zu validieren. So musste sichergestellt werden, dass keine Erkennung in der Luft, über einem Gewässer, innerhalb eines Gebäudes oder

bei Reflexionen von glänzenden Oberflächen, Wandmalereien oder Werbetafeln erfolgte. Darüber hinaus plante das Projektteam die Entwicklung eines Autoencoders, der die Umgebung des Fußgängers berücksichtigt und anhand von Kenntnissen über das normale Fahrverhalten vorhersagt, wie sich ein Fußgänger in einer bestimmten Szene wahrscheinlich bewegen würde. Derselbe Autoencoder würde verwendet werden, um eine Anomalie in der Teil- oder Gesamttrajektorie eines Fußgängers zu erkennen, wenn der Rekonstruktionsfehler einen bestimmten vorgegebenen Schwellenwert überschreitet.

Das Team konzentrierte sich auch auf die Durchführung von Literaturrecherchen und die Entwicklung der oben genannten Konzepte zur Aufnahme in ein Weißbuch.

In der Anfangsphase des zweiten Projektjahres konzentrierte sich die AVL auf drei Hauptziele: die Fertigstellung des Wahrnehmungsalgorithmus, die Integration der Software in den TP4-Demonstrator und die Durchführung von Leistungsbewertungen an einer Reihe von Datensätzen.

In AP3.1 konzentrierte sich AVL auf die physikalischen Wissensquellen, d.h. physikalische und mathematische Beziehungen, um die Ergebnisse des KI-Modells zur Fußgängererkennung und -verfolgung gemäß UC1 zu untermauern. In Bezug auf E3.1.2 setzte AVL die Forschung und Entwicklung des Modells zur Erkennung von Anomalien fort und definierte die physikalischen Grenzen der Zustandsvariablen des Fußgängers, einschließlich Geschwindigkeit, Beschleunigung und Winkelgeschwindigkeit. Darüber hinaus implementierte unser Team physikalische Plausibilitätsprüfungen auf der Grundlage zweidimensionaler Bewegungsgleichungen (z. B. konstante Drehrate und Beschleunigung) für den ausgewählten Anwendungsfall und analysierte den Positionsfehler des Fußgängers (x- und y-Koordinaten) auf der Grundlage der Ausgabe des Tracking-Algorithmus. Anschließend wurden diese Positionsfehler und Ausreißer innerhalb der Grenzen der Zustandsvariablen im nächsten Schritt mit einem Plausibilitätsscore von 0 bis 1 bewertet.

In Bezug auf AP3.2 konzentrierte sich AVL auf die Quellen von Welt- und Expertenwissen, insbesondere räumliches Wissen (geografische und visuelle Konzepte) und Verkehrswissen (soziale und rechtliche Normen), mit dem Ziel, die Ergebnisse des KI-Modells für die Fußgängererkennung und -verfolgung in UC1 zu untermauern. Während dieses Zeitraums begann die AVL mit der Arbeit an E3.2.2, der Konzeptualisierung des Weltwissens aus den Trainingsdaten für den ersten Anwendungsfall. Wie in AP3.1 bestand das Ziel darin, die Erkennung von Anomalien in einem Plausibilitätswert zwischen 0 und 1 abzubilden, dieses Mal auf der Grundlage des in den Trainingsdaten vorhandenen Weltwissens.

In Bezug auf AP3.3 und 3.4 nahm die AVL eine aktive Rolle in den Workshop-Diskussionen mit den Projektpartnern ein. AVL teilte sachdienliche Informationen über die Integration der Module in den Demonstrator mit, so dass die Teams mit der Integration fortfahren konnten.

In der zweiten Jahreshälfte 2022 konzentrierte sich AVL auf mehrere Schlüsselaktivitäten, um das Projekt voranzutreiben. Es wurden Gespräche zwischen den TP3- und TP4-Gruppen der AVL aufgenommen, um die Schnittstellen mit dem Demonstrator zu koordinieren und effiziente Validierungsmethoden für die Einhaltung der UC1-Szenarien zu entwickeln. Ziel dieser Gespräche war es, eine nahtlose Integration und Validierung der entwickelten Module zu gewährleisten.

In AP3.2 hat AVL einen konformitätsbasierten Ansatz angewandt, der eine Kombination aus semantischen Kartenschichten aus der Vogelperspektive (BEV) verwendet, die sich in verschiedenen Fußgängereigenschaften widerspiegeln. Das Team analysierte zunächst diese Attribute (Fußgängerverteilung, Geschwindigkeit, Höhe, Menschendichte, Sichtbarkeit und Verfolgungskonsistenz), indem es die Erkennungen auf verschiedene Schichten aufteilte und die Vorhersagen als "echte Positive" und "Falsch-Positive" kategorisierte. Auf der Grundlage dieser Analyse wurde ein XGBoost-Regressor trainiert, um diese Attribute zu einem einzigen Plausibilitätswert zu kombinieren.

In AP3.3 ging es in erster Linie darum, das Modul "Extrahiertes Wissen" zu implementieren, die drei Wissensquellen in ROS mit dem AVL AD-Stack zu integrieren und alle Module zu einem einzigen Plausibilitätsbewertungssystem zu kombinieren. Diese Phase war entscheidend, um die Komponenten des Projekts aufeinander abzustimmen und eine umfassende Prüfung und Validierung vorzubereiten.

In der ersten Hälfte des Jahres 2023 schloss AVL die Umwandlung des Positionsfehlers in eine Plausibilitätsbewertung in AP3.1 erfolgreich ab. Das Erkennungskonzept wurde anschließend anhand von Offline-Daten aus dem nuScenes-Datensatz, einem umfangreichen Anwendungsdatensatz für autonomes Fahren, verifiziert.

Das Team schloss auch die Schulung und Evaluierung des 3D-Erkennungsmoduls in der CARLA-Simulationsumgebung mit simulationsbasierten LiDAR-Daten ab und implementierte einen Algorithmus zur Objektverfolgung.

In Bezug auf AP3.2 wurde das Wissensmodul erfolgreich implementiert und auf dem Offline-Datensatz ausgeführt. Zusätzlich wurde die Anomalie in eine Plausibilitätsbewertung umgewandelt, die auf dem aus den Trainingsdaten abgeleiteten Weltwissen basiert.

In AP3.3 schlug die AVL vor, das gewonnene Wissen über Verkehrsregeln, Rechtsnormen und Fußgängerverhalten in Verkehrsszenarien für die Formulierung von extrahierten Wissenskonzepten zu nutzen. Die Wissensquelle für diese Formalisierung wurde direkt aus der Straßenverkehrsordnung (StVO) und aus speziellen Fallstudien abgeleitet, die durchgeführt wurden, um Einblicke in das Fußgängerverhalten in Verkehrsszenarien zu gewinnen. Das Ende des vergangenen Jahres entwickelte Konzept wurde weiter verfeinert.

In Bezug auf AP3.4 hat die AVL das Konzept für die Kombination aller zuvor entwickelten Wissensblöcke abgeschlossen. Der 3D-Detektor wurde in die ROS-Umgebung integriert, und eine vorläufige Integration des Moduls in den TP4-Demonstrator und den AD-Stack wurde erfolgreich abgeschlossen. Das integrierte Modul wurde auch in einem der Simulationsszenarien für UC1 (nämlich Szenario 1.1) getestet, die das AVL-Team in TP4 in CARLA entwickelt hat.

In der letzten Phase des Projekts, für AP3.1, passte AVL das Modul für physikalisches Wissen, das zuvor auf dem NuScenes-Datensatz trainiert worden war, an die CARLA-Simulationsumgebung an. Das Modul wurde dann in den AD-Stack integriert und mit einem 3D-LiDAR-Detektor in Szenario 1.1 getestet, in dem ein stehendes Fahrzeug einen Fußgängerüberweg verdeckt. Schließlich analysierte das Team die Leistung des Erkennungsmoduls in Kombination mit dem bereits vorhandenen Objektverfolgungsalgorithmus mithilfe speziell entwickelter Auswertungsskripte.

Für AP3.2 hat AVL das Weltwissen-Modul an die CARLA-Simulationsumgebung angepasst, nachdem es mit dem NuScenes-Datensatz trainiert wurde. Außerdem wurde der LiDAR-3D-Detektor mit dem SHIFT-Datensatz neu trainiert. Das Modul wurde dann in den AD-Stack integriert und getestet, einschließlich einer Analyse seiner Leistung unter Verwendung benutzerdefinierter Auswertungsskripte.

In AP3.3 identifizierte die AVL die Straßenkartenebene als ein Schlüsselkonzept für die Analyse, das aus dem größeren Wissensfundus extrahiert wurde. Das Team führte erste Tests durch, um die Eigenschaften von Fußgängern an verschiedenen Orten zu bewerten, darunter auf der Straße, auf dem Parkplatz und auf dem Gehweg.

In AP3.4 setzte die AVL eine Kombination von Methoden ein, um die Konsistenz der Erkennungen zu verbessern. Das Team erreichte dies durch die Konsolidierung aller zuvor entwickelten Wissensmodule und die Optimierung der Hyperparameter des 3D-Detektors und des Trackers. Darüber hinaus wurde ein Debug-Visualisierer integriert, um den Vergleich zwischen den vorhergesagten Ergebnissen und den tatsächlichen Daten zu erleichtern. Schließlich erstellte das Team ein Skript, um das Funktionsniveau sowohl des Basismoduls als auch des in TP3 entwickelten neuen Moduls zu bewerten.

Die Tests wurden mit dem TP4-Demonstrator unter Verwendung von Szenario 1.1 durchgeführt. Der gesamte in AP3.1-AP3.3 entwickelte Code ist im GitLab-Repository des Projekts verfügbar.

3.1.2 TP4

Das Hauptziel des Teilprojekts 4 (TP4) war die Einrichtung einer Simulations- und Testumgebung zur Integration und Erprobung aller KI-basierten Komponenten und Methoden, die von den Projektpartnern in anderen TPs entwickelt wurden. Dies beinhaltet die Prüfung ihrer Leistung auf Komponentenebene und als Teil eines komplexeren autonomen Fahrsystems. Der AD-Stack wurde während des gesamten Projekts schrittweise entwickelt, wobei die Funktionalität bei jeder Iteration sichergestellt und gleichzeitig neue Funktionen und verbesserte Fähigkeiten auf der Grundlage der Anforderungen der Partner hinzugefügt wurden.

Das erste Demonstrationskonzept wurde in der ersten Projektphase erstellt. Die Steuerungsmodule, das Herzstück des AD-Stacks, wurden in die CARLA-Simulationsumgebung integriert und das gesamte System in einem ersten Szenario getestet. Die Fähigkeiten des Demonstrators wurden dann erweitert, um verschiedene Fahrsituationen abzudecken, so dass die Projektpartner ihre Module integrieren, testen und bewerten konnten.

Zu Beginn des Projekts hat die AVL die Arbeit an den Arbeitspaketen 4.1 und 4.2 aufgenommen.

Das Ziel des ersten Arbeitspakets bestand darin, die in der Projektbeschreibung ausgewählten Anwendungsfälle zu verfeinern. Dies beinhaltete die Erstellung genauerer Grenzen und Szenarien für die drei Anwendungsfälle aus der Projektbeschreibung sowie die Festlegung von Metriken und KPIs, die anschließend zur Bewertung der Leistung der im Projekt entwickelten Methoden und Module verwendet wurden.

AVL leistete einen wesentlichen Beitrag zu den Ergebnissen von E4.1.1, indem wir die Anforderungen und Parameter für die Definition der Szenariogrenzen definierten. Darüber hinaus

haben wir bei der Umwandlung von Anwendungsfällen und Szenarien in eine formale Darstellung geholfen. Dies beinhaltete die Einführung und Darstellung der formalen Beschreibung für zwei Beispielszenarien, einschließlich der Konzepte der funktionalen und logischen Beschreibungen und der sechs Szenario-Ebenen aus dem Pegasus-Projekt. Schließlich glichen wir die KPIs mit den Anwendungsfällen ab, indem wir die derzeit verfügbaren Kritikalitätsmetriken mit den drei Anwendungsfällen verknüpften.

AP4.2 konzentrierte sich auf die Definition eines Gesamtsystems mit allen notwendigen Komponenten für das autonome Fahren. Dazu mussten sich die an diesem Arbeitspaket beteiligten Partner auf mehrere Themen einigen und diese diskutieren, die als Grundlage für die weitere Entwicklung und Umsetzung im Gesamtprojekt dienen sollten, z.B. das Schnittstellenkonzept zwischen den von den verschiedenen Partnern entwickelten Komponenten, die Definition von Datenformaten und Prozessen, die Definition eines Integrations- und eines Architekturkonzepts usw.

Die AVL war der Arbeitspaketleiter für dieses Arbeitspaket und war verantwortlich für die Koordination der Diskussionen zwischen den Partnern, die Zuweisung von Aufgaben zu den jeweiligen Meilensteinen und die Vorbereitung von Berichten und Unterlagen für die Arbeitspaketlieferungen. Auf der technischen Seite begann die AVL ihre Beiträge zu diesem Arbeitspaket mit der Arbeit an E4.2.2.

Während der Projektbeschreibungsphase bot AVL an, seinen eigenen autonomen Antriebsstack als Basis für den in diesem Projekt zu entwickelnden Demonstrator-Stack beizusteuern. AVL leitete die Arbeit ein, indem sie die derzeit verfügbaren Fähigkeiten des AD-Stacks und die Möglichkeiten zur Realisierung dieser Schnittstelle vorstellte, wobei der Austausch privater und vertraulicher Daten zwischen den Partnern vermieden werden sollte. AVL entwickelte und präsentierte vier verschiedene Vorschläge für die Schnittstellenarchitektur.

Alle Projektteilnehmer waren sich einig, dass das Stack allen Partnern über einen öffentlichen Server zur Verfügung gestellt werden sollte, so dass jeder Teilnehmer, der mit dem Stack interagieren möchte, dies über eine Ethernet-Schnittstelle tun kann (Abbildung 2).

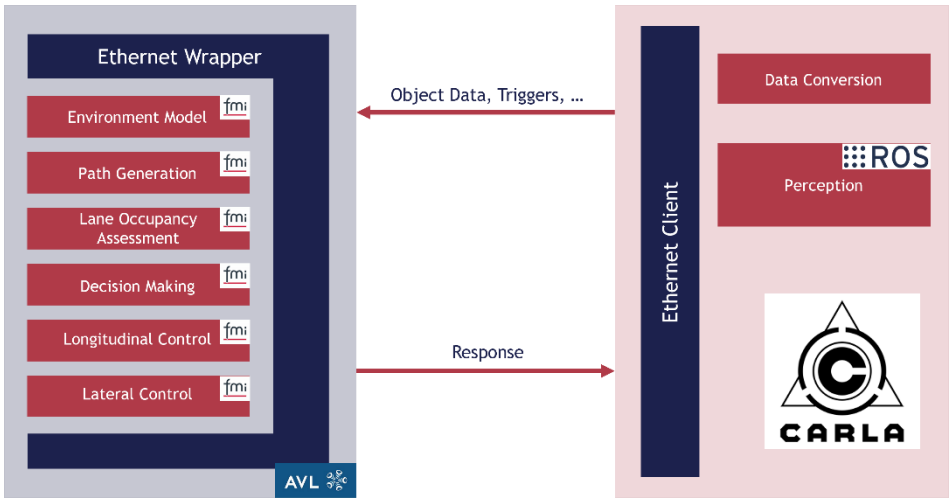

Abbildung 2: Gemeinsames Demonstrator-Konzept.

Dadurch erhielten die Partner mehr Flexibilität, um an ihren eigenen Entwicklungen zu arbeiten, ihre eigene verfügbare Infrastruktur zu nutzen und die Daten der Partner zu schützen. AVL begann die Entwicklung mit dem Ziel, noch vor Ende des ersten Projektjahres einen testbereiten Prototyp zu haben.

Im gleichen Zeitraum konnte die AVL auch zur Auswahl von CARLA als Simulationswerkzeug für den endgültigen Demonstrator beitragen. Das AVL-Team arbeitete an der Definition von generischen Komponenten, die in der endgültigen Version des AD-Stacks benötigt werden, und berücksichtigte dabei auch die Fähigkeiten und Einschränkungen von CARLA in "E4.2.3 - AD-Stack-Architektur und Auswahl bestehender Softwarekomponenten". Schließlich trugen wir zu "E4.2.4 - Projektübergreifende Workflow-Definition, APIs, Datenformate, Integrationsprozess für die frühestmögliche Implementierung der kontinuierlichen Integration im Entwicklungsprozess" bei, indem wir die Schnittstellendefinition zwischen den Partnern in mehreren von uns organisierten Treffen in der ersten Jahreshälfte koordinierten. AVL hat auch zu Themen beigetragen, die den Austausch von Informationen und Ergebnissen aus verschiedenen Projekten der KI-Familie betreffen.

In der zweiten Jahreshälfte 2021 hat die AVL die Arbeit an AP4.1 und 4.2 fortgesetzt und auch Aktivitäten im Zusammenhang mit AP4.3 und 4.4 begonnen.

AVL trug zu E4.1.1 bei, indem sie Anforderungen und Parameter zur Begrenzung der Szenariogrenzen definierte. Wir verglichen die KPIs mit den Anwendungsfällen, indem wir eine Verbindung zwischen den derzeit verfügbaren Kritikalitätsmetriken und den drei Anwendungsfällen aus der Projektbeschreibung herstellten.

AVL trug zu E4.2.1 bei, indem es neue Anforderungen für den AD-Stack, die Simulationsumgebung und die Schnittstellen zwischen beiden schuf. In E4.2.3 erstellte AVL logische und physikalische Architekturen, um nicht nur den AD-Stack, sondern auch die Schnittstellen mit CARLA und mit den in TP 1, 2 und 3 entwickelten Methoden und Modulen besser zu beschreiben. In E4.2.2 und E4.2.4 moderierte AVL alle Diskussionen und gab Feedback zu Sensorauswahl, Datenformaten und dem CI/CD-Pipeline-Konzept.

Das erste Ziel des Arbeitspakets 4.3 war die Erstellung eines Proof of Concept (PoC), der aus einem System besteht, das den von AVL bereitgestellten autonomen Antriebsstapel effizient in die gewählte Simulationsumgebung integriert.

Für E4.3.1 stellte AVL den AD-Stack auf einem öffentlichen Server bereit und richtete alle Schnittstellen ein, um die Kommunikation mit CARLA zu ermöglichen.

In Bezug auf AP4.1 begann die AVL damit, die Durchführbarkeit der Anwendungsfälle im Hinblick auf die Datenerfassung in der Praxis zu bewerten. Zu diesem Zweck wurden die Anwendungsfälle im Hinblick auf das Risiko bewertet, das sie für die Verkehrsteilnehmer und die aufzeichnenden Fahrzeuge darstellen. Für die als ungefährlich eingestuften Szenarien wurden Standorte gesucht, an denen die Aufzeichnung durchgeführt werden kann, und ein möglicher strategischer Ansatz definiert.

AVL bereitete sein Fahrzeug für die reale Datenerfassung vor und führte eine erste Kalibrierung aller Sensoren durch. Die Sensoren, die verwendeten Technologien und die Einbaupositionen wurden dokumentiert. Die Spezifikation des zu verwendenden Aufzeichnungsdatenformats wurde aus dem KI Data Tooling Projekt übernommen, an dem AVL ebenfalls zur Datengenerierung beteiligt war.

In AP4.1 bestand unsere erste Aufgabe in der ersten Hälfte des zweiten Projektjahres darin, den Beitrag E4.1.1 für den ersten Projektmeilenstein (MS1) fertigzustellen. Dazu gehörten der Abschluss der Aufgaben zur Definition der Anwendungsfallgrenzen, die Überprüfung des Szenariokatalogs und die Zuordnung der ausgewählten Metriken zu den einzelnen Anwendungsfällen. Die AVL unterstützte auch die Formatierung, Überprüfung und Genehmigung des Berichts.

In Bezug auf AP4.2 moderierte die AVL als AP-Leiterin in diesem Zeitraum mehrere Sitzungen, kümmerte sich um die Planung der Aufgaben der Partner und die Überwachung der Meilensteine, koordinierte die Diskussionen der Partner zu Themen im Zusammenhang mit dem Demonstrator, leitete potenzielle Risiken an die PMT-Runde weiter und präsentierte die Ergebnisse dieses Arbeitspakets während eines "Open Project Day".

Für E4.2.1 sammelte AVL neue Anforderungen für den Demonstrator, den AD-Stack, die Schnittstellen und die Integration. Für E4.2.2 unterstützte unser Team häufig andere Partner mit dem Demonstrator und lieferte Klarstellungen zu Schnittstellen und Integration. Darüber hinaus wurden Verbesserungen an der Dokumentation des Demonstrators vorgenommen, um die Integrationsarbeit der Partner zu erleichtern. In E4.2.3 bereitete AVL mehrere Präsentationen vor, um die definierte Architektur des Demonstrators für die Projektpartner zu verdeutlichen. Schließlich wurde in E4.2.4 die CI/CD-Strategie für den endgültigen Demonstrator weiter diskutiert und definiert.

Zu diesem Zweck hat AVL in Zusammenarbeit mit Capgemini einen Docker-Container entwickelt, der die Integration der Partnermodule in den Demonstrator ermöglicht.

AVL leitete auch das Arbeitspaket 4.3 und war verantwortlich für die Moderation regelmäßiger Treffen mit den Partnern, die Überwachung von Aufgaben und Meilensteinen, die Koordination von Themen zwischen den Partnern, die Eskalation von Risiken in der PMT-Runde und die Präsentation der Ergebnisse innerhalb und außerhalb des Projekts.

Im Hinblick auf die Lieferung des Demonstrator-PoC in E4.3.1 arbeitete AVL daran, die Integration des AD-Stacks in die CARLA-Simulationsumgebung zu vervollständigen, auch dank der Unterstützung von Capgemini durch die Entwicklung einer Funktion zur Extraktion von Straßenpolylinien für die korrekte Interpretation der Umgebung. Im Rahmen von E4.3.2 führte AVL eine Evaluierung der bestehenden CARLA-Szenarien ("CARLA Towns") mit dem Ziel durch, die in AP4.1 beschriebenen Szenarien zu realisieren und zu reproduzieren. Nach Abschluss der Entwicklungsphase im ersten Halbjahr 2022 war der Demonstrator nun in der Lage, sowohl die CARLA-Standardszenarien als auch ein Demoszenario im OpenSCENARIO-Format auszuführen.

Darüber hinaus wurde festgestellt, dass während der VHB-Entwicklungsphase die Verantwortlichkeiten für die Erstellung von Szenarien für die Simulationsumgebung keinem

Partner zugewiesen wurden, was zu einer erheblichen Lücke im Entwicklungsprozess des Demonstrators führte. AVL griff dieses Problem auf dem PMT-Treffen auf und bot den Partnern neue Ressourcen für die Generierung von OpenDRIVE-Dateien sowie kostenlose Lizenzen für die Nutzung des AVL-eigenen Tools, des AVL Scenario Designers, für die Generierung von OpenSCENARIO-Dateien an.

In Bezug auf AP4.4 wurden in der ersten Hälfte des Jahres 2022 zusätzliche Anpassungen und Klarstellungen in Bezug auf Datenformate und Kalibrierungsparameter vorgenommen.

Darüber hinaus wurde eine zusätzliche Bewertung der Anwendungsfälle und des Szenariokatalogs aus AP4.1 durchgeführt, um deren Relevanz für jeden Partner und die notwendigen Details zu ermitteln, die erfasst werden müssen. Valeo und AVL führten außerdem einen Workshop mit allen Projektpartnern durch, um offene Fragen zur Datenerfassung zu klären. Dies ermöglichte es allen AP4.4-Partnern, einen ersten Plan für Datenerfassungskampagnen zu entwickeln.

In diesem Zeitraum nahm AVL auch an den ersten Diskussionen über GUA3 (Real Data Labeling) und GDPR-Anforderungen teil. Beide Themen wurden auch in der PMT-Runde vorgestellt und zwischen den Partnern diskutiert.

In der zweiten Jahreshälfte 2022 hat die AVL erhebliche Fortschritte bei den Aktivitäten für E4.2.1 gemacht, insbesondere in Bezug auf die Anforderungen an den Demonstrator, den AD-Stack, die Schnittstellen und die Integration. Im Vorgriff auf E4.2.2 unterstützte unser Team die Partner regelmäßig bei ihrer Arbeit mit dem Demonstrator. Darüber hinaus erstellte AVL eine detailliertere Dokumentation, in der jede Komponente des AD-Stacks erläutert wird, um den Partnern eine intuitivere Erfahrung bei der Durchführung der Integration zu ermöglichen. Das Team sammelte auch Daten von allen Partnern, um ihr Interesse an den spezifischen Modulen des Stacks zu ermitteln. Im Rahmen von E4.2.3 lieferte AVL sowohl bei internen als auch bei externen Präsentationen häufig Klarstellungen zur definierten Architektur des Demonstrators. Schließlich wurden in E4.2.4 weitere wichtige Klarstellungen bezüglich der CI/CD-Strategie für den endgültigen Demonstrator diskutiert.

In Bezug auf AP4.3 lieferte AVL Aktualisierungen zur Entwicklung von Szenarien innerhalb der Simulationsumgebung unter Verwendung des AVL Scenario Designers. Es wurde eine Reihe von Anpassungen untersucht, um eine optimale Schnittstelle zwischen diesem Tool und CARLA zu gewährleisten. Darüber hinaus wurden zwei Szenarien (1.1 und 2.4, wie im Szenarienkatalog beschrieben) entwickelt und den Partnern zur Verfügung gestellt. Das Team informierte auch über die wesentlichen Verbesserungen der AD-Stack-Funktionen und ging ausführlich auf die unternommenen Anstrengungen zur Fehlerbehebung ein.

Das Team führte eine Bewertung durch, um die wichtigsten Einschränkungen und erforderlichen Aktualisierungen des AD-Stacks zu ermitteln, um die im AP4.1-Szenarienkatalog festgelegten funktionalen Anforderungen zu erfüllen. Es wurde ein umfassender Überblick über die wichtigsten Herausforderungen sowohl auf der Ebene der Anwendungsfälle als auch der Szenarien erstellt. Das Dokument wurde dann als Grundlage für Diskussionen mit jedem Partner verwendet, um die endgültigen Fähigkeiten des Demonstrators zu bestimmen.

Am Ende des zweiten Projektjahres hatte die AVL einen Demonstrator entwickelt, der in der Lage war, einige Szenarien für die Anwendungsfälle 1 und 2 auszuführen und verschiedene Module zu integrieren.

AVL unterstützte den AP-Leiter bei der Koordination der AP4.4-Aktivitäten und überwachte die Aufgaben und den Umfang aller Partner. Darüber hinaus initiierte AVL die Sammlung von Daten aus dem realen Fahrbetrieb und sammelte im Laufe einer zweitägigen Aufzeichnungskampagne 89 Sequenzen. Die Daten wurden in das Projektformat konvertiert und einer gründlichen Prüfung unterzogen, um die Synchronisation, die Richtigkeit der Kalibrierung und die Vollständigkeit sicherzustellen. AVL entwickelte einen Plan zur Durchführung weiterer Aufzeichnungskampagnen, um die geplante Anzahl von Bildern zu erreichen.

In diesem Zeitraum hat die AVL auch die Vereinbarung über die gemeinsame Datenverarbeitung zwischen den Partnern von KI Wissen unterzeichnet und damit den sicheren Umgang mit Daten gemäß der DSGVO ermöglicht.

Da es in der VHB keine Zuständigkeiten für die Generierung synthetischer Daten gab, übernahm die AVL die Organisation eines Workshops zwischen den Partnern, bei dem die Anforderungen an synthetische Daten gesammelt und eine Bewertung der Fähigkeiten jedes Partners zur Datengenerierung vorgenommen wurde.

Das Projekt AP4.5 begann in der zweiten Hälfte des Jahres 2022. Die AVL hat viele der relevanten Themen im Rahmen der APs 4.2 und 4.3, für die die AVL die AP-Leitung innehatte, behandelt, um die verzögerten Maßnahmen in AP4.5 zu kompensieren. Das Fehlen einer präzisen Definition von Anforderungen und Messgrößen für den endgültigen Demonstrator, verbunden mit der fehlenden Überwachung des Integrationsstatus der Partner, stellte jedoch ein erhebliches Risiko für den Projektzeitplan dar. AVL bot für dieses AP umfangreiche technische Unterstützung an und lieferte Lösungen für die Integrationsprobleme der Projektpartner.

In der Anfangsphase des dritten Projektjahres konzentrierte sich das AVL-Team auf zwei Hauptziele: die Fertigstellung der Anforderungen an den AD-Stack und die Simulationsumgebung (E4.2.1) und die Definition der notwendigen Schnittstellen zwischen dem AD-Stack und den von den Partnern in TP1-3 entwickelten Modulen (E4.2.2). AVL führte eine Reihe von Entwicklungsaktivitäten zur Verbesserung des AD-Stacks durch und unterstützte die Partner kontinuierlich bei der Arbeit am Demonstrator und der Integration ihrer jeweiligen Module. In diesem Zusammenhang organisierte AVL auch einen Workshop, in dem das Team verschiedene Themen vorstellte, darunter die Generierung von Szenarien, die Verwendung von Skripten zur Parametrisierung von Szenarien, die Einführung und Demonstration des neuen AD-Stacks mit Trajektorienvorhersagefunktionen sowie die Klärung offener Fragen mit den Partnern. Auch die nächsten Schritte wurden besprochen. Während dieser Zeit arbeitete das AVL-Team auch an der Dokumentation des AD-Stacks und der Simulationsumgebung sowie an der Koordination und Pflege des Kiw Avl Hwp Repository in GitLab. Im Rahmen von E4.2.3 war keine weitere Entwicklung der AD-Stack-Architektur erforderlich, obwohl das AVL-Team die Partner regelmäßig über die aktuelle Demonstrator-Architektur informierte.

Der ursprüngliche Zeitplan sah den Abschluss von AP4.2 bis zum Ende des zweiten Quartals 2023 vor. Einige Aufgaben in E4.2.2, E4.2.3 und E4.2.4 waren jedoch am Ende des Quartals noch nicht abgeschlossen. Die Hauptgründe dafür waren Verzögerungen bei der Entwicklung und Integration der Module bei einigen Partnern, die sich auf die Fertigstellung der Schnittstellen auswirkten, sowie die Notwendigkeit weiterer Diskussionen und Untersuchungen zu Datenformaten und Metadaten.

Im Rahmen von AP4.3 führte die AVL mit jedem der Partner Einzelgespräche. Ziel war es, ein tieferes Verständnis für den Umfang der Methoden und Module der einzelnen Partner und deren Integrationsstatus zu erlangen und etwaige Probleme oder Bedenken zu ermitteln. Darüber hinaus sollten die Treffen dazu dienen, Anforderungen zu sammeln, um die ordnungsgemäße Integration der KI-Module in den Demonstrator sicherzustellen. Darüber hinaus wurden Pläne für die künftige Entwicklung der erforderlichen Funktionen erörtert und Klarheit über den AD-Stack und den Demonstrator geschaffen.

Nach von AVL koordinierten Gesprächen mit Partnern, die an der Objekterkennung arbeiten, wurde deutlich, dass es eine Diskrepanz zwischen den von ihnen entwickelten Modulen und den Schnittstellen des AD-Stacks gab. Darüber hinaus wurde festgestellt, dass einige der in der Entwicklung befindlichen Module nicht in der Lage waren, Objekt-IDs zu verfolgen, was eine entscheidende Komponente für die optimale Funktion des AD-Stacks ist. AVL ermöglichte die Zusammenarbeit mit Capgemini, das eine Lösung anbot, und berief ein Treffen ein, bei dem Capgemini den Partnern seine Lösung vorstellte und erläuterte. Schließlich erwies sich diese Gesprächsrunde als nützlich, um den Status der Partner zu klären, die sich mit der Auslegung von Verkehrsregeln und -vorschriften befassen. Diese Partner bekundeten ihr Interesse, ihre Methoden mit dem AVL-Demonstrator zu demonstrieren, verfügten aber nicht über die Fähigkeit, die erforderlichen Module zu entwickeln und zu implementieren. Die AVL erleichterte die Zusammenarbeit zwischen den Partnern bei der Entwicklung und Integration eines Moduls, das auf dem in ihren Methoden definierten Regelwerk basiert.

Darüber hinaus erstellte AVL eine einheitliche Liste (Integrationsanforderungen, Problemliste und Nachverfolgung), in die die Partner alle Probleme eintragen konnten, die bei der Integration ihrer Module in den Demonstrator oder während der Simulation auftraten. Auf diese Weise konnte das AVL-Team das Problem beurteilen und dem betreffenden Partner Hilfestellung geben. Darüber hinaus führte das AVL-Team zahlreiche Debugging-Sitzungen mit den Partnern durch, um Probleme, die während der Nutzung des Demonstrators auftraten, zu identifizieren und zu beheben.

Um die Partner bei der Integration ihrer Module und der Einrichtung zusätzlicher Sensoren, die während der Simulation benötigt werden, zu unterstützen, erstellte AVL einen zusätzlichen GitLab-Zweig (AVL_DemoMockModule), der ein Beispielmodul nur für Demonstrationszwecke enthält, zusammen mit einer Anleitung zur Konfiguration des Demonstrators und zum Ausführen des integrierten Moduls. Das AVL-Team stellte außerdem Anweisungen zur Konfiguration neuer Sensoren und zur Auswahl des Simulationsszenarios für die Ausführung in CARLA sowie ein Skript zur Parametrisierung des Szenarios und zur Erstellung von Szenariovariationen zur Verfügung, das den Partnern zur Verfügung gestellt wurde. Darüber hinaus untersuchte AVL die Verfügbarkeit von

Verkehrsschildern in CARLA, um einen der Partner bei der Entwicklung eines Szenarios mit gegnerischen Verkehrsschildern zu unterstützen, und die Ergebnisse der Evaluierung wurden gemeinsam genutzt und dokumentiert.

In AP4.4 spielte AVL eine aktive Rolle in den Diskussionen über die Generierung von synthetischen und realen Daten, die Erstellung von Simulationsszenarien, das Datenformat und, als neuere Aufgabe, die Extraktion von Straßeninformationen. AVL ermöglichte auch einen Workshop für den AP-Leiter, an dem alle Projektpartner teilnahmen, um Probleme im Zusammenhang mit der Generierung synthetischer und realer Daten anzusprechen und Lösungen für offene Fragen zu finden. Im Hinblick auf die Szenariengenerierung hat AVL nicht nur zur Entwicklung verschiedener Simulationsszenarien beigetragen, sondern auch Partner unterstützt, die eine Lizenz für den AVL Scenario Designer beantragt haben. Um dies zu erleichtern, fungierte AVL als Vermittler mit dem Lizenzierungsteam, klärte Schritte im Lizenzierungsprozess und bot technische Unterstützung, wo dies möglich war. Darüber hinaus führte die AVL mehrere Aufnahmekampagnen mit ihrem Aufnahmefahrzeug durch und sammelte zusätzliche Datensequenzen (E4.4.2, E4.4.3).

In Bezug auf AP4.5 hat AVL die Verzögerung von Aktionen innerhalb dieses Arbeitspakets angesprochen, indem die damit verbundenen Themen und Abhängigkeiten in den APs 4.2 und 4.3 diskutiert wurden. Darüber hinaus trug das AVL-Team zur Entwicklung von Bewertungsmetriken für UC1 bei, indem es ein Skript erstellte, das die Zeit bis zur Kollision mit einem vorderen Objekt auf der Fahrspur des AD-Fahrzeugs bewertet.

In der zweiten Hälfte des Jahres 2023 konzentrierte sich das AVL-Team auf die Fertigstellung der erforderlichen Schnittstellen zwischen dem AD Stack und den von den Partnern in AP1-3 entwickelten Modulen (E4.2.2). AVL verbesserte den AD Stack durch Entwicklungsaktivitäten und leistete den Partnern technische Unterstützung bei der Integration ihrer jeweiligen Module in den TP4-Demonstrator. Im Rahmen von E4.2.3 waren keine wesentlichen Änderungen an der AD-Stack-Architektur erforderlich. AVL koordinierte jedoch kleinere Änderungen, um die Integration der Module eines Partners im Anwendungsfall 3 zu ermöglichen.

Im Hinblick auf AP4.3 entwickelte das AVL-Team alle notwendigen Funktionen, um den Einsatz des AD-Stacks in allen geplanten Anwendungsfällen zu ermöglichen (E4.3.3). Zu den bemerkenswerten Errungenschaften gehören die Entwicklung einer Funktion zur Erkennung von Straßenschildern, die es ermöglicht, die gewünschte Geschwindigkeit des AD-Fahrzeugs auf der Grundlage der erkannten Geschwindigkeitsbegrenzung einzustellen, und die Verbesserung des AD-Stacks, um sich auf nicht-ideale Erkennungen zu stützen, wodurch er in die Lage versetzt wird, Fehldetektionen bei der Objekterkennung durch Partnermodule anzugehen. Darüber hinaus wurde der AD-Stack so erweitert, dass das AD-Fahrzeug in bestimmten Szenarien eine durchgezogene Linie überqueren kann, z. B. wenn ein stehendes Fahrzeug den Verkehrsfluss auf der AD-Fahrspur behindert (Abbildung 3).

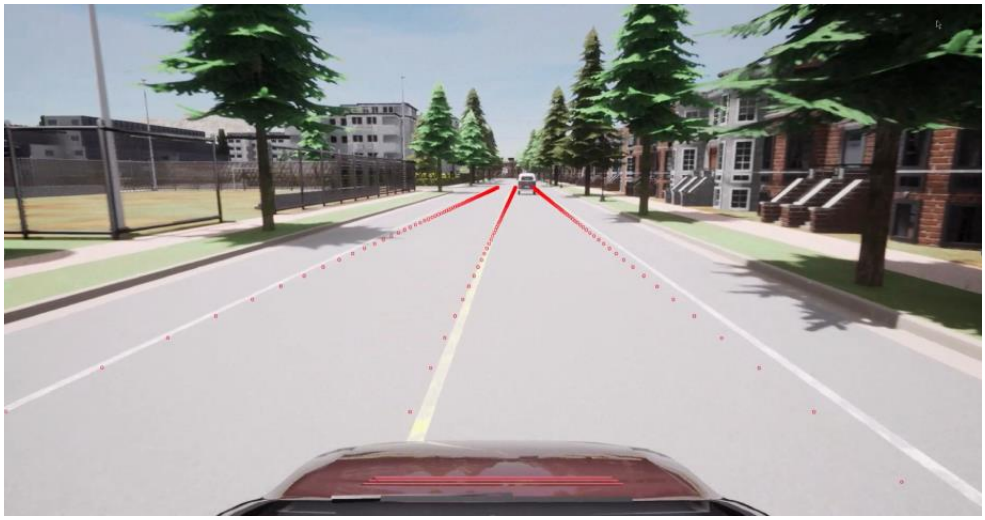

Abbildung 3: Das Simulationsbild zeigt, wie das Ego-Fahrzeug einen Fahrspurwechsel einleitet, der eine Überquerung der durchgezogenen Linie erforderlich macht, nachdem es ein stehendes Fahrzeug auf der Fahrspur erkannt hat (Szenario 3.2).

Nachdem die grundlegende Funktionalität eingerichtet war, fuhr das Team fort, die Funktion zu erweitern, um den Versatz zwischen dem AD-Fahrzeug und dem zu umfahrenden Objekt einzustellen. Am Ende des Jahres 2023 implementierte das RBL-Team auf Wunsch eines Projektpartners eine zusätzliche Funktion. Damit konnte das AD-Fahrzeug einen Fahrspurwechsel durchführen, wenn auf der aktuellen Fahrspur ein Baustellensignal erkannt wird. Alle Erweiterungen des AD-Stacks wurden dokumentiert, und den Projektpartnern wurden zusätzliche Informationen zur Einrichtung der verschiedenen Funktionen zur Verfügung gestellt. AVL arrangierte auf Wunsch auch individuelle Treffen mit den Partnern, um alle Bedenken und Fragen in Bezug auf den AD-Stack und die Simulationsumgebung zu klären.

AVL förderte weiterhin die Verwendung einer gemeinsamen Liste, in der die Partner alle Integrations- oder Simulationsprobleme melden konnten, auf die sie bei der Einrichtung oder dem Betrieb des TP4-Demonstrators stießen. So konnte das AVL-Team jedes Problem effizient analysieren und mit dem jeweiligen Partner besprechen. Die Liste erleichterte auch die Lösung von Problemen und den rechtzeitigen Austausch von Lösungen mit anderen Partnern. Das AVL-Team stellte auch zusätzliche Anleitungen zur Verfügung, um die Partner bei einer Reihe von Aufgaben zu unterstützen, z. B. bei der Erstellung von Fahrspurkonfigurationsdateien für die Verwendung in Simulationsszenarien.

In AP4.4 entwickelte AVL eine Reihe von Simulationsszenarien, darunter 1.2, 1.3 und 2.5, sowie zusätzliche Varianten. Im Hinblick auf die Bereitstellung von Realdaten (E4.4.3) schloss AVL die Nachbearbeitung von Daten, die während früherer Aufzeichnungskampagnen gesammelt wurden, ab, um sie mit den Anforderungen des Projekts an das Datenformat in Einklang zu bringen, und bereitete sie für die Annotation vor. Das Team konzentrierte sich auch auf die Extraktion von Metadaten, insbesondere von Straßeninformationen aus OpenStreetMap, und konvertierte sie in das ASAM OpenDRIVE-Format. AVL unterstützte das Projekt weiterhin mit dem AVL Scenario Designer und verteilte neue Schulungsvideos an die Partner.

In Bezug auf AP4.5 hat das Team das Bewertungsskript für die Zeit bis zur Kollision aktualisiert, um die Verbesserungen im AD-Stack zu berücksichtigen.

3.2 3.2 Zahlenmäßiger Nachweis

3.2.1 TP3

Der innovative Ansatz von AVL integriert physikalisches und weltweites Expertenwissen für eine verbesserte Fußgängererkennung und stellt eine wertvolle Lösung für die Branche dar. Die Methode generiert einen Konformitätswert, der als Konfidenzwert für weitere Analysen verwendet werden kann und eine wertvolle zusätzliche Metrik darstellt. Die Ausgabe des Moduls für physikalische Konformität wird als Maske über dem Modul für Welt- und Expertenwissen verwendet.

Um die Durchführbarkeit dieses Ansatzes zu bewerten, verwendete AVL einen 3D-Detektor mit einem Tracker als Basis und setzte ihn sowohl in öffentlichen als auch in AD-Stack-Umgebungen ein.

Unsere Ergebnisse deuten auf verbesserte Erkennungsfähigkeiten hin, wie die durchschnittliche Genauigkeitskennzahl zeigt (Abbildung 4), für Szenen innerhalb des 50-Meter-Bereichs in UC1.1-UC1.5-Szenarien.

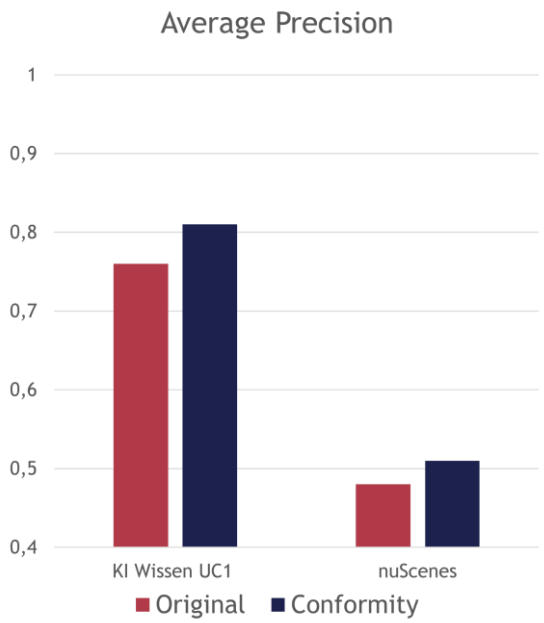

Abbildung 4: Vergleich der durchschnittlichen Genauigkeit zwischen dem Basismodell und dem angepassten Modell. Für die Daten der KI Wissen wurden fünf Szenen aus UC1 verwendet.

3.2.2 TP4

Es ist nicht möglich, numerische Ergebnisse für die meisten der in TP4 durchgeführten Aktivitäten zu präsentieren, da das Hauptziel dieser Aktivitäten die Entwicklung eines gemeinsamen Demonstrators war. Die vom Team entwickelten Verbesserungen des AD Stack sowie die Simulationsszenarien wurden anschließend von den Partnern in ihren Simulationen eingesetzt, was

zu Ergebnissen führt, die überwiegend qualitativ und anwendungsbezogen und nicht quantifizierbar sind.

Im folgenden Abschnitt werden die Ergebnisse der Erweiterung des AD-Stacks um die Objektvorhersage vorgestellt. Wenn die Vorhersagefunktion aktiviert ist, wird der AVL-AD-Stack in mehreren Instanzen erstellt, die der Anzahl der Schritte entsprechen, für die eine Vorhersage gemacht werden muss. Anschließend wird die Ausgabe jeder Instanz arbitriert und verwendet, um die entsprechenden Steuerbefehle für das Ego-Fahrzeug abzuleiten. Auf diese Weise kann das Ego-Fahrzeug zeitnah auf eine vorhergesagte Objektposition reagieren, wodurch eine abrupte Verzögerung und die Notwendigkeit einer Notbremsung vermieden werden.

Wie in den folgenden Diagrammen dargestellt (Abbildung 5: Von oben nach unten: Längsposition des erkannten vorderen Objekts, Beschleunigungsanforderung des Längsreglers, Beschleunigung des Ackermann-Reglers, auf Gas und Bremse normierte Werte. Fall mit Vorhersagen.), erkennt die vierte Stack-Instanz zum Zeitpunkt = 4s die vorhergesagte Position des Fußgängers in ihrem Fahrkorridor und reduziert den Beschleunigungsbedarf. Es ist jedoch bald zu beobachten, dass der Bedarf erhöht wird, da der Fußgänger nun den Fahrkorridor überquert hat. Umgekehrt erhält die dritte Stack-Instanz nun eine Vorhersage, die den Beschleunigungsbedarf weiter reduziert. Die Arbitrierungslogik wählt die niedrigste der Beschleunigungsanforderungen aus den Stack-Instanzen, einschließlich des Hauptstacks, aus und verwendet sie, um den am besten geeigneten Steuerbefehl für das Ego-Fahrzeug anzuwenden.

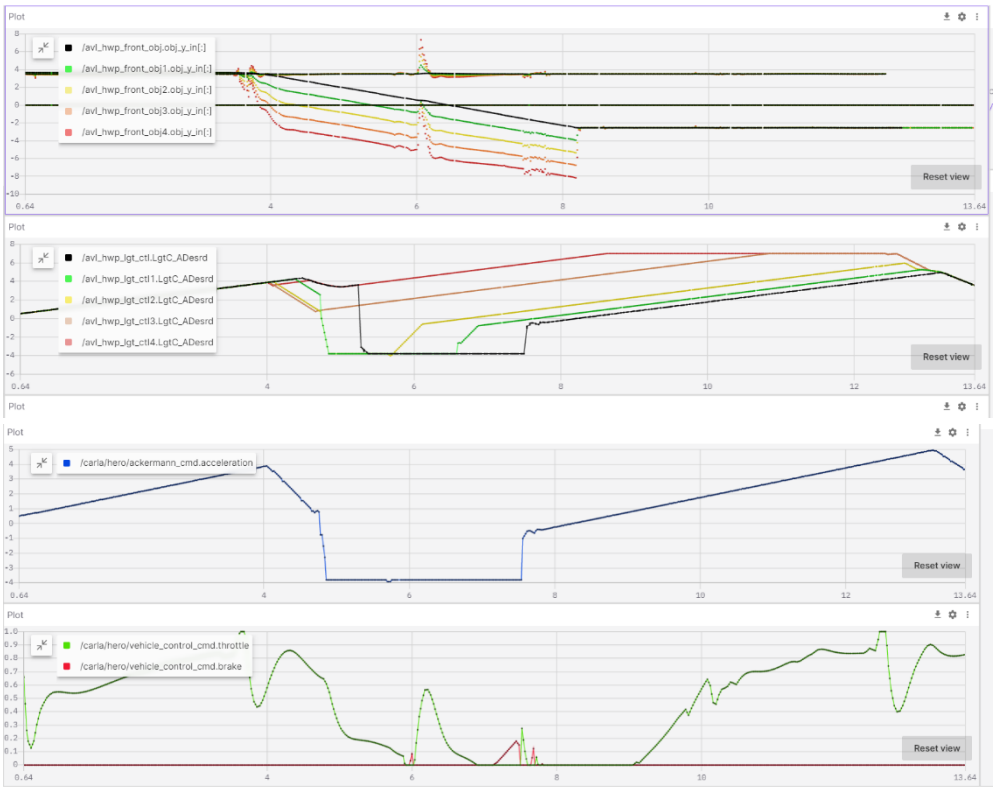

Abbildung 5: Von oben nach unten: Längsposition des erkannten vorderen Objekts, Beschleunigungsanforderung des Längsreglers, Beschleunigung des Ackermann-Reglers, auf Gas und Bremse normierte Werte. Fall mit Vorhersagen.

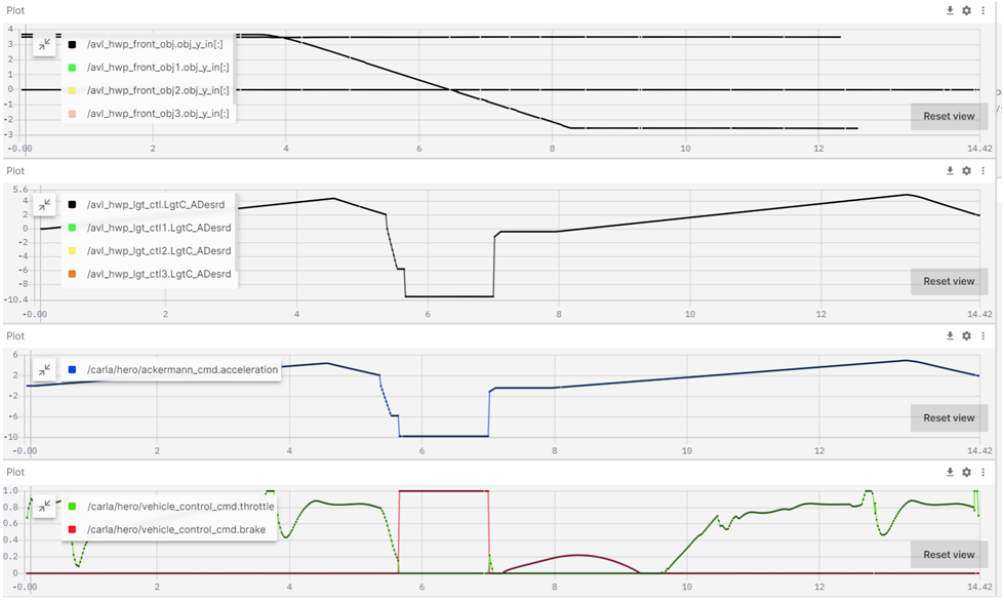

Abbildung 6: Von oben nach unten: Längsposition des erkannten vorderen Objekts, Beschleunigungsanforderung des Längsreglers, Beschleunigung des Ackermann-Reglers, auf Gas und Bremse normierte Werte. Fall ohne Vorhersagen.

Wie in dem Beispiel ohne Vorhersagen dargestellt (Abbildung 6), sind die Beschleunigungswerte (negativ, da sie sich auf die Abbremsung beziehen) deutlich höher.

3.3 Notwendigkeit der Förderung

Die Förderung des KI-Wissen-Projekts hat unsere Forschungs- und Entwicklungsarbeit im Bereich der autonomen Fahrfunktionen maßgeblich ermöglicht. Ohne diese Unterstützung wäre es nicht möglich gewesen, die umfangreichen und komplexen Aufgaben zu bewältigen, die mit der Entwicklung eines umfassenden AD-Stacks, der Entwicklung einer KI-basierten Fußgängererkennungsfunktion, der Durchführung mehrerer Kampagnen zur Aufzeichnung realer Fahrdaten sowie der Einrichtung eines gemeinsamen Demonstrators, der für alle Partner aus der Ferne zugänglich ist, verbunden sind. Diese Aktivitäten sind nur einige von vielen, die ohne diese Unterstützung nicht durchgeführt worden wären.

Die bereitgestellten finanziellen Mittel ermöglichten uns den Zugang zu den notwendigen Werkzeugen und Ressourcen, einschließlich spezieller Software, Hardware und hochqualifiziertem Personal. Die Finanzierung ermöglichte es uns, innovative Ansätze zu verfolgen und neue Technologien zu entwickeln. Insbesondere die Integration externer Softwarekomponenten und die Schaffung einer interoperablen Simulationsplattform haben unsere Fähigkeit zur Zusammenarbeit und Entwicklung erheblich verbessert.

Die Finanzierung ermöglichte es uns, wertvolle Partnerschaften mit anderen Forschungseinrichtungen und Partnern aus der Industrie einzugehen, die den Wissenstransfer und die gemeinsame Nutzung von Ressourcen und Fachwissen erleichterten.

Das Wissen und die Technologien, die im Rahmen des Projekts entwickelt werden, haben das Potenzial, erhebliche positive Auswirkungen auf die wissenschaftliche Gemeinschaft und die Industrie zu haben.

3.4 Nutzen und Verwertbarkeit

Unsere Erfahrung mit KI Wissen hat uns wertvolle Einblicke in eine Reihe von Schlüsselbereichen gegeben, die für die Entwicklung und Prüfung fortschrittlicher autonomer Fahrfunktionen relevant sind. Die Schaffung eines umfassenden AD-Stacks, der externen Nutzern den Zugang und die Integration ihrer eigenen Softwarekomponenten ermöglicht, hat uns das nötige Fachwissen vermittelt, um künftige Zusammenarbeit und Wachstum zu erleichtern. Dieser Ansatz fördert nicht nur die Innovation, sondern stellt auch sicher, dass unsere Lösungen vielseitig sind und sich an unterschiedliche Nutzerbedürfnisse anpassen lassen.

Unsere Untersuchungen des AVL Scenario Designers und des CARLA-Simulators für Interoperabilität haben unser Fachwissen in diesem Bereich weiter verbessert. Diese Tools haben sich bei der Schaffung realistischer und vielfältiger Testumgebungen, die für die Validierung der Robustheit und Zuverlässigkeit von AD-Systemen von entscheidender Bedeutung sind, als unschätzbar erwiesen. Die Möglichkeit, diese Simulatoren nahtlos in unsere Arbeitsabläufe zu integrieren, hat unsere Testeffizienz und -genauigkeit erheblich verbessert und es uns ermöglicht, Aufgaben auf eine straffere und genauere Weise zu erledigen.

Darüber hinaus ebnet das Fachwissen, das bei der Extraktion von Daten aus einer Geodatenbank wie OpenStreetMap und ihrer Konvertierung in ein simulationsfreundliches Format wie ASAM OpenDRIVE gewonnen wurde, den Weg für zukünftige Entwicklungen und Anwendungen. Diese Fähigkeit ermöglicht es uns, sehr detaillierte und genaue Simulationsszenarien zu erstellen, die für die Entwicklung sicherer und zuverlässiger AD-Systeme unerlässlich sind. Die Nutzung von Open-Source-Geodaten ermöglicht es uns, kosteneffiziente, skalierbare Simulationen zu erstellen, die für ein breites Spektrum von Anwendungen zugänglich sind.

3.5 Veröffentlichungen

Das AVL-Team lieferte Beiträge zu drei gemeinsamen Weißbüchern, die die Projektergebnisse für die Jahre 2021, 2022 und 2023/2024 zusammenfassen. Diese Papiere basierten auf den in TP3 erzielten Ergebnissen.

3.5.1 Erfolgte Veröffentlichungen

Es gibt keine weiteren veröffentlichten Publikationen.

3.5.2 Geplante Veröffentlichungen

Derzeit sind keine Publikationen geplant.

3.5.3 Schutzrechtsanmeldungen

Es sind keine Schutzrechtsanmeldung im Verlauf des Projektes erfolgt.

4 Literaturverzeichnis

[1] Holger Caesar et al. "nuScenes: A multimodal dataset for autonomous driving". In: arXiv Preprint arXiv:1903.11027 (2019).

[2] Alex H. Lang et al. "PointPillars: Schnelle Kodierer für die Objekterkennung aus Punktwolken". In: CoRR abs/1812.05784 (2018). arXiv: 1812.05784. url: http://arxiv.org/abs/1812.05784.

[3] Harold W. Kuhn. "Die ungarische Methode für das Zuordnungsproblem". In: Naval Research Logistics Quarterly 2.1-2 (Mar. 1955), S. 83-97. doi: 10.1002/nav.3800020109.

[4] Alexey Dosovitskiy et al. "CARLA: Ein offener städtischer Fahrsimulator". In: Proceedings of the 1st Annual Conference on Robot Learning. 2017, pp. 1-16.

[5] Ashwell, M., Gunn, P., & Gibson, S. (2012). Waist-to-height ratio is a better screening tool than waist circumference and BMI for adult cardiometabolic risk factors: systematic review and meta-analysis. Obesity Reviews, 13(3), 275-286.

KI WISSEN
Automotive AI Powered by Knowledge

Zusammenfassung

Herausgeber	AVL Software and Functions GmbH
Erstellungsdatum	20.09.2024

AVL leistete Beiträge zum Projekt KI Wissen in zwei der vier Teilprojekte (TPs), nämlich TP3, Wissenskonformität, und TP4, Enabler, Integration und Demonstration.

Das Ziel von TP3 war es, Fälle zu identifizieren, in denen KI-Entscheidungen von bestehendem Wissen abweichen. Dies wurde durch die Nutzung einer Reihe von Wissensquellen erreicht, darunter physikalisches und mathematisches Wissen (AP3.1 Physikalische Beziehungen), allgemeines Umweltwissen oder domänenspezifisches Fachwissen (AP3.2 Welt- und Expertenwissen), durch Lernen gewonnenes Wissen (AP3.3 Extrahierte Konzepte) und eine Kombination verschiedener Arten von Wissen (AP3.4 Kombination von Methoden). Die in diesem Teilprojekt entwickelten Methoden würden insbesondere in sicherheitskritischen Szenarien die Konformität mit der geforderten Wissensbasis sicherstellen.

AVL hat eine neue Methode entwickelt, um die Standort- und Zustandsattribute von erkannten Fußgängern zu kombinieren und eine Entscheidungsgrenze zu schaffen. Dieser aktualisierte Ansatz bietet größere Zuverlässigkeit und verbesserte Leistung in realen Anwendungen.

Wir testeten unseren Ansatz anhand eines realen Datensatzes (nuScenes) und synthetischer Daten, die im Rahmen des KI Wissen-Projekts (AP4.4) erzeugt wurden. Für das Basismodell wählten wir einen LiDAR-basierten 3D-Detektor (PointPillars) mit einem ungarischen assoziationsbasierten Tracker. Die Methode verwendet die folgenden Attribute zur Berechnung des Plausibilitätsscores:

- 3D-Detektorausgabe (Seitenverhältnis, Verdeckung, Konfidenzwert)
- Kartenebenen (Fahrspur, Parkzone, Kreuzung, Haltelinie und Gehweg)
- Zustandsraum (Geschwindigkeit, Beschleunigung, zurückgelegter Weg)

Die Ergebnisse zeigen eine bemerkenswerte Leistungssteigerung des kombinierten Konformitätsansatzes, wenn er auf den Basis-3D-Detektor angewendet wird. Wir erreichten eine Verbesserung von 6 % im nuScenes-Datensatz und eine Verbesserung von 6,5 % im synthetischen Datensatz.

Im Hinblick auf TP4 bestand das Hauptziel dieses Teilprojekts darin, eine Simulations- und Testumgebung einzurichten, um alle KI-basierten Komponenten und Methoden zu integrieren und zu bewerten, die von den Projektpartnern in anderen TPs entwickelt wurden.

TP4 bestand aus fünf Arbeitspaketen (APs): zwei konzeptionelle Arbeitspakete (AP4.1 Use Cases, Gütekriterien und Metriken; AP4.2 Gesamtsystemkonzept), gefolgt von einem Entwicklungs- und Integrationsarbeitspaket (AP4.3 Implementierung und Integration AD-Stack). Das vierte Arbeitspaket (AP4.4, Erzeugung und Bereitstellung Datensätze) war für die Sammlung von realen und synthetischen Datensätzen und die Erstellung von Simulationsszenarien verantwortlich. Das letzte Arbeitspaket (AP4.5, Evaluation und Demonstration) ermöglichte es den Projektpartnern, ihre neu entwickelten Komponenten in vollem Umfang zu demonstrieren.

AVL übernahm die Verantwortung für die Koordination und die Ergebnisse dieses TPs sowie für die Koordination und die Ergebnisse der Arbeitspakete 4.2 und 4.3.

Der AD-Stack wurde während des gesamten Projekts schrittweise entwickelt, wobei die Funktionalität in jeder Phase sichergestellt und gleichzeitig neue Funktionen und erweiterte Möglichkeiten auf der Grundlage der Anforderungen der Partner integriert wurden.

Das erste Demonstrationskonzept wurde in der ersten Projektphase entwickelt. Die Steuerungsmodule, die den Kern des AD-Stacks bilden, wurden in die CARLA-Simulationsumgebung integriert und das gesamte System in einem vorläufigen Szenario getestet.

Der Aufbau des gemeinsamen Demonstrators war mit mehreren Herausforderungen verbunden. Eine der ersten Herausforderungen bestand darin, den Entwicklungsprozess so zu gestalten, dass eine schrittweise Integration möglich ist und nicht erst am Ende des Projekts. Mit diesem Ansatz sollte sichergestellt werden, dass die Integration ein integraler Bestandteil des Entwicklungsprozesses ist.

Ein weiterer wichtiger Aspekt war, dass die Implementierungsdetails der AD-Stack-Kernmodule, der Informationsfluss im Gesamtsystem und die Verarbeitung der Sensordaten von der Implementierung der neuen Komponenten getrennt werden konnten. Dies geschah mit dem Ziel, den Projektpartnern ein Maximum an Flexibilität bei der Gestaltung ihrer KI-basierten Module zu ermöglichen.

Im Laufe des Projekts wurden die Fähigkeiten des Demonstrators erweitert, um eine Reihe von Fahrszenarien abzudecken und den unterschiedlichen Bedürfnissen unserer Projektpartner gerecht zu werden.

Eines der Hauptergebnisse dieses Teilprojekts war die Erstellung und Bereitstellung von Datensätzen. AVL stellte den Projektpartnern einen Datensatz mit insgesamt 57 Sequenzen zur Verfügung. Darüber hinaus wurden die Datensätze mit Kartendaten aus ASAM OpenStreetMap angereichert und anhand der GPS-Koordinaten der Aufnahmefahrzeuge in das OpenDRIVE-Format konvertiert. Darüber hinaus konnte das TP4-Demonstrationssystem genutzt werden, um synthetische Daten zu generieren, die für weitere Tests und Evaluierungen der neu entwickelten Komponenten von Vorteil sind.

Im Laufe des Projekts sahen sich die PMT und der Lenkungsausschuss mit einer Reihe von Risiken konfrontiert, die identifiziert worden waren. Zu Beginn herrschte eine gewisse Unklarheit über die Zuständigkeit der VHB für die Szenarienerstellung. Seit dem zweiten Jahr des Projekts bietet

AVL den Partnern kostenlose Lizenzen für den AVL Scenario Designer an, ein von der AVL-Zentrale entwickeltes Tool.

Während der Integrationsphase gab es einige Verzögerungen aufgrund von Koordinationsproblemen zwischen den notwendigen Arbeiten im Demonstrator und der Integration der Komponenten durch die Partner. Den Partnern wurde keine klare Frist für die Integration der neu entwickelten Komponenten in den Demonstrator gesetzt, was zu einigen Schwierigkeiten bei der Einhaltung des Gesamtzeitplans des Projekts führte. Die Projektverlängerung um drei Monate ermöglichte jedoch den erfolgreichen Abschluss aller Aktivitäten.

KI WISSEN

Automotive AI Powered by Knowledge

Erfolgskontrollbericht

Berichtszeitraum: 01.01.2021 - 31.03.2024

AVL, AVL Software and Functions GmbH

Vorhabenbezeichnung	**KI Wissen - Entwicklung von Methoden für die Einbindung von Wissen in maschinelles Lernen**
Laufzeit des Vorhabens	**01.01.2021 - 31.03.2024**
Förderkennzeichen	19A20020D
Fälligkeitsdatum	01.10.2024
Erstellungsdatum	20.09.2024

Finanziert von der Europäischen Union
NextGenerationEU

Gefördert durch:
Bundesministerium für Wirtschaft und Klimaschutz
aufgrund eines Beschlusses des Deutschen Bundestages

Inhaltsverzeichnis

1 Beitrag des Ergebnisses zu den förderpolitischen Zielen 3

2 Wissenschaftlich-technische Ergebnisse 4

3 Fortschreibung des Verwertungsplans 5

3.1 Wirtschaftliche Erfolgsaussichten nach Projektende 5

3.2 Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende 5

3.3 Wissenschaftliche und wirtschaftliche Anschlussfähigkeit 5

4 Einhaltung der Kosten- und Zeitplanung 6

1 Beitrag des Ergebnisses zu den förderpolitischen Zielen

AVL trug auf verschiedene Weise zu den Projektzielen bei. Im Hinblick auf die Wissenskonformität (TP3) haben wir eine Methode zur Fußgängererkennung entwickelt, die physikalisches Wissen, Welt- und Expertenwissen sowie extrahiertes Wissen umfasst.

Für die Themen Enabler, Integration und Demonstration (TP4) haben wir einen gemeinsamen Demonstrator erstellt, um vordefinierte Fahrszenarien für verschiedene Anwendungsfälle genau zu simulieren. AVL erstellte die Architektur für den AD-Stack, definierte die notwendigen Schnittstellen und die zugehörigen ROS-Themen und integrierte den Control Stack in die CARLA-Simulationsumgebung.

Der gemeinsame Demonstrator ermöglichte es den Projektpartnern, ihre eigenen neu entwickelten KI-Funktionen und -Komponenten in einen umfassenden AD-Stack zu integrieren und ihre Leistung in verschiedenen Fahrszenarien zu bewerten. Unser Team trug auch zur Erstellung mehrerer Simulationsszenarien und Szenariovarianten bei, die auf den in dem zu Beginn des Projekts definierten Katalog beschriebenen Szenarien basieren.

AVL trug auch zur Bereitstellung von realen Fahrdaten bei, die mit unserem Aufzeichnungsfahrzeug während mehrerer Aufzeichnungskampagnen gesammelt wurden.

2 Wissenschaftlich-technische Ergebnisse

Die von der AVL in TP3 entwickelte kombinierte Methode reichert den Ort des erkannten Objekts mit seinen Zustandsraumattributen an, um eine Entscheidungsgrenze zu definieren. Dank dieser Erweiterung sind die Erkennungen zuverlässiger und die Gesamtleistung verbessert sich in realen Anwendungen.

Der AD-Stack des RBL wurde während der gesamten Projektlaufzeit weiterentwickelt, um die Anforderungen der Partner zu erfüllen und jedem Anwendungsfall (UC) gerecht werden zu können. Insbesondere für die Ausführung der Szenarien in UC1 entwickelten wir eine automatische Notbremse, wir erweiterten die Anzahl der vorderen Objekte, die das Stack verarbeiten kann, um Szenarien mit mehreren Fußgängern zu bewältigen, und wir passten unser Stack an, um potenzielle Einbußen bei der Objekterkennung in den Wahrnehmungsfunktionen zu berücksichtigen, was zu einer realistischeren Leistung führte, als die Projektpartner ihre neu entwickelten Wahrnehmungsmodule integrierten.

Für die Ausführung von Szenarien in UC2 entwickelte das Team die Funktion zur Vorhersage der Flugbahn, die auch in UC1-Szenarien verwendet werden kann, um Bremsvorgänge im Voraus einzuleiten und starke Verzögerungen zu vermeiden. Darüber hinaus haben wir Funktionen für die Erkennung von Verkehrszeichen entwickelt, z. B. Geschwindigkeitsanpassung auf der Grundlage der erkannten Geschwindigkeitsbegrenzung oder Fahrspurwechsel aufgrund der Erkennung eines Schildes, das auf eine Baustelle hinweist.

Bei UC3 schließlich konzentrierten wir uns auf die Funktionalität, die mit dem Überfahren von durchgezogenen Linien verbunden ist, um ein stehendes Hindernis zu umgehen, das den normalen Verkehrsfluss behindert. Wir haben die Funktion um die Möglichkeit erweitert, den seitlichen Versatz zwischen dem AD-Fahrzeug und dem feststehenden Objekt auf der Grundlage der Anforderung des Moduls des integrierten Partners anzupassen.

Was die Bereitstellung der realen Daten betrifft, so hat AVL die realen Daten aufgezeichnet und anschließend nachbearbeitet, um eine hohe Qualität zu gewährleisten, bevor die Sequenzen an das Beschriftungsunternehmen weitergegeben wurden. Wir stellten insgesamt 57 Sequenzen zur Verfügung, die wir mit Straßennetzinformationen anreicherten. Wir nutzten die relevanten GNSS-Daten (Global Navigation Satellite System) aus den aufgezeichneten Sequenzen, um zunächst detaillierte Straßeninformationen aus OpenStreetMap (OSM) zu extrahieren und sie dann in das ASAM OpenDRIVE-Format zu konvertieren, ein standardisiertes Format zur Darstellung von Straßennetzen in digitaler Form, dass die Verwendung der Daten in der Simulation erleichtert.

Um die Extraktion und Konvertierung von Straßendaten zu rationalisieren und zu automatisieren, haben wir Skripte entwickelt, die speziell darauf ausgelegt sind, die gesammelten Daten zu analysieren, nur die vordefinierten Merkmale zu extrahieren und sie in das gewünschte Format zu konvertieren, um Effizienz und Genauigkeit bei der Verarbeitung großer Datensätze zu gewährleisten und die erforderlichen Zusatzinformationen bereitzustellen.

AVL half auch bei der Definition von Metriken für die Bewertung der integrierten Module im TP4-Demonstrator und trug mit der Implementierung der Time-to-Collision-Metrik zu der Reihe von Bewertungsmetriken bei.

3 Fortschreibung des Verwertungsplans

Das Projekt KI Wissen hat maßgeblich dazu beigetragen, unser Verständnis und unsere Fähigkeiten bei der Entwicklung und Erprobung fortschrittlicher Funktionen für das autonome Fahren (AD) zu verbessern. Durch die Kommerzialisierung unseres AD-Stacks, das Angebot von Beratungs- und Simulationsdienstleistungen und die Entwicklung von Lösungen für die Datenerfassung und -nachbearbeitung konnten wir Innovation und Wachstum im Bereich des autonomen Fahrens vorantreiben.

3.1 Wirtschaftliche Erfolgsaussichten nach Projektende

Der im Rahmen des KI Wissen-Projekts entwickelte umfassende AD-Stack könnte als Produkt oder Dienstleistung vermarktet werden. Unternehmen, die AD-Technologien entwickeln, könnten diesen Stack nutzen, um ihre Funktionsentwicklung zu beschleunigen und ihre eigenen Lösungen nahtlos zu integrieren. Diese Kommerzialisierung könnte neue Einnahmequellen erschließen und die branchenweite Innovation fördern.

Das durch die Arbeit mit dem AVL Scenario Designer und der CARLA-Simulationsumgebung erworbene Wissen könnte genutzt werden, um fortschrittliche Simulationsdienste anzubieten. Diese Dienstleistungen könnten sich an Unternehmen richten, die realistische und umfassende Simulationsumgebungen für die Prüfung ihrer AD-Systeme benötigen. Durch die Bereitstellung hochwertiger Simulationsdienste könnten wir die Entwicklung und Validierung modernster AD-Technologien unterstützen.

Der Prozess der Konvertierung von Geodatenbankdaten in simulationsfreundliche Formate könnte zu einem eigenständigen Dienst oder Tool entwickelt werden. Diese Lösung könnte an Organisationen vermarktet werden, die genaue Simulationsdaten für ihre AD-Entwicklung und -Tests benötigen. Das Angebot solcher Lösungen für die Extraktion und Konvertierung von Straßendaten könnte einen kritischen Bedarf in der Branche decken und die Genauigkeit und Zuverlässigkeit von AD-Simulationen verbessern.

3.2 Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende

Die im Rahmen des KI Wissen-Projekts geleistete Vorarbeit eröffnet zahlreiche Möglichkeiten für künftige Forschung und Entwicklung. Die kontinuierliche Verbesserung des AD-Stacks, der Simulationswerkzeuge und der Prozesse zur Extraktion und Konvertierung von Straßendaten könnte zu innovativen Lösungen und Fortschritten im AD-Bereich führen. Indem wir an der Spitze von Forschung und Entwicklung bleiben, können wir zur kontinuierlichen Weiterentwicklung der Technologien für autonomes Fahren beitragen.

3.3 Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Mit dem im Rahmen des Projekts erworbenen Fachwissen sind wir gut positioniert, um anderen Organisationen, die ihre AD-Fähigkeiten entwickeln oder verbessern wollen, Beratungsdienste anzubieten. Potenzielle Kooperationen mit Automobilherstellern, Technologieunternehmen und Forschungseinrichtungen könnten geprüft werden, um AD-Technologien weiter voranzubringen. Diese Partnerschaften könnten zu für beide Seiten vorteilhaften Ergebnissen führen und die Branche vorantreiben.

4 Einhaltung der Kosten- und Zeitplanung

Das Projekt war ursprünglich für einen Zeitraum von drei Jahren, von Anfang 2021 bis Ende 2023, geplant. Aufgrund unvorhergesehener Umstände musste der Zeitplan jedoch in der zweiten Hälfte des dritten Jahres angepasst werden. Es wurde eine Verlängerung um drei Monate, von Januar bis März 2024, gewährt. Die Verlängerung hatte keine zusätzlichen Kosten zur Folge, und das Gesamtbudget blieb im Rahmen des ursprünglichen Plans.

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel KI Wissen - Entwicklung von Methoden für die Einbindung von Wissen in maschinelles Lernen	
4. Autor(en) [Name(n), Vorname(n)] Dr Paolicelli, Federica Meichel Matthias	5. Abschlussdatum des Vorhabens 31.03.2024
	6. Veröffentlichungsdatum
	7. Form der Publikation Schlussbericht
8. Durchführende Institution(en) (Name, Adresse) AVL Software and Functions GmbH Im Gewerbepark B29 93059 Regensburg	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19A20020D
	11. Seitenzahl 33
12. Fördernde Institution (Name, Adresse) Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. Literaturangaben 5
	14. Tabellen 2
	15. Abbildungen 6
16. Zusätzliche Angaben	
17. Vorgelegt bei (Titel, Ort, Datum)	
18. Kurzfassung Der Abschlussbericht der AVL Software and Functions GmbH enthält die Ergebnisse des Unternehmens für das Förderprojekt KI Wissen. Das Hauptziel des Projekts bestand darin, verschiedene Wissensquellen in KI-basierte Funktionen, Komponenten und Methoden für das autonome Fahren zu integrieren. Dabei wurden die Herausforderungen der Datenabhängigkeit durch die Kombination datengesteuerter Lösungen mit wissensbasierten Ansätzen angegangen. Diese Integration würde die Verständlichkeit, Zuverlässigkeit und Qualität von KI-Funktionen beim autonomen Fahren Neben diesem Hauptziel bestand das Projektziel darin, einen gemeinsamen Demonstrator zu erstellen, mit dem die Projektpartner die neu entwickelten Funktionen in Fahrszenarien bewerten können, die in einem projektspezifischen Katalog definiert sind.	
19. Schlagwörter KI, autonomes Fahren, Stapel, Demonstrator, Simulation, Fußgängererkennung, CARLA, OpenDRIVE, OpenSCENARIO	
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 - developing methods for incorporating knowledge into machine learning (KI Wissen - Entwicklung von Methoden für die Einbindung von Wissen in maschinelles Lernen)	
4. author(s) (family name, first name(s)) Dr Paolicelli, Federica Meichel Matthias	5. end of project 31.03.2024
	6. publication date
	7. form of publication Final Report
8. performing organization(s) (name, address) AVL Software and Functions GmbH Im Gewerbepark B29 93059 Regensburg	9. originator's report no.
	10. reference no. 19A20020D
	11. no. of pages 33
12. sponsoring agency (name, address) Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. no. of references 5
	14. no. of tables 2
	15. no. of figures 6
16. supplementary notes	
17. presented at (title, place, date)	
18. abstract The final report from AVL Software and Functions GmbH includes the company's results for the funding project KI Wissen. The project's primary objective was to integrate diverse sources of knowledge into AI-based functions, components, and methods for autonomous driving. In doing so, the project addressed the challenges of data dependency by combining data-driven solutions with knowledge-based approaches. This integration would enhance the comprehensibility, reliability, and quality of AI functions in autonomous driving. In addition to this primary objective, the project aimed to establish a shared demonstrator, allowing project partners to assess the newly developed functions in driving scenarios defined in a project-specific catalog.	
19. keywords AI, autonomous driving, stack, demonstrator, simulation, pedestrian detection, CARLA, OpenDRIVE, OpenSCENARIO	
20. publisher	21. price