



Verbundprojekt:

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

## Schlussbericht zum Teilvorhaben

Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien

Berichtszeitraum	<b>01.01.2021 bis 31.12.2023</b>
Zuwendungsempfänger	LiangDao GmbH
Förderkennzeichen	<b>19A20026E</b>
Laufzeit des Vorhabens	01.01.2021 - 31.12.2023
Leiter des Teilvorhabens	Dr. Andreas Eich; Dr. Yang Ji
Telefon	0173/4695820; 0152/08637006
E-Mail	andreas.eich@liangdao.de, yang.ji@liangdao.de
Version	1.0
Erstellungsdatum	27.06.2024



Finanziert von der  
Europäischen Union  
NextGenerationEU

Gefördert durch:



aufgrund eines Beschlusses  
des Deutschen Bundestages

## Inhaltsverzeichnis

0 Zusammenfassung .....	1
1 Kurzdarstellung.....	2
1.1 Aufgabenstellung .....	2
1.2 Voraussetzungen des Vorhabens .....	3
1.3 Planung und Ablauf des Vorhabens .....	6
1.4 Wissenschaftlicher und technischer Stand .....	7
1.5 Zusammenarbeit mit anderen Stellen.....	11
2 Eingehende Darstellung.....	12
2.1 Verwendung der Zuwendung und erzielttes Ergebnis .....	12
2.2 Zahlenmäßiger Nachweis .....	57
2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit.....	57
2.4 Voraussichtlicher Nutzen .....	58
2.5 Fortschritte bei anderen Stellen .....	59
2.6 Veröffentlichung der Ergebnisse .....	60
3 Literaturverzeichnis.....	63

## 0 Zusammenfassung

Zum Nachweis der sicheren Funktion von hochautomatisierten Fahrzeugen werden nach dem aktuellen Stand der Technik fest definierte Szenarienkataloge zum manöverbezogenen Nachweis sowie mehrere Millionen Fahrkilometer umfassende Echtzeitdaten zum statistischen Nachweis herangezogen.

Die umfangreichen Daten werden benötigt, um die durch KI getroffenen Entscheidungen validieren, verbessern und reproduzieren zu können, mit dem Ziel die notwendige Testabdeckung für zukünftige Funktionalitäten zu erreichen.

Zur Entwicklung neuer Fahrzeuge mit Automatisierungslevel 4-5 ist es unabdingbar, den Aufwand zum Einfahren der Echtzeitdaten und dem Erstellen der Szenarienkataloge zu reduzieren. Ziel muss es sein, eine selektive Erfassung relevanter und kritischer Fahrsituationen, signifikanter Umgebungsdaten sowie der Rohdaten der Fahrzeugsensorik schon während des Fahrbetriebs zu erreichen.

Im Rahmen des Projektes KIsSME wurden wie in Abbildung 1 dargestellt KI-basierte Algorithmen erarbeitet und angewendet, die OnBoard-Systeme ermöglicht, relevante und kritische Szenarien in Echtzeit zu erkennen und hierfür selektiv Rohdaten sowie Szenarienschreibungen zu erfassen. Im Text wird die Gesamtheit der erarbeiteten Infrastruktur als „KIsSME-Pipeline“ bezeichnet.

Die KI-basierten Algorithmen ermöglichen eine inhärente Lernfähigkeit, welche das Erkennen von kritischen Situationen und der zugehörigen relevanten Daten stetig verbessern, um für die Entwicklung von automatisierten Systemen der Level 4-5 die Informationsdichte der für die Erprobung genutzten Daten zu steigern und gleichzeitig die hierfür notwendigen Datenvolumen sowie Aufwände zur Sicherstellung des Datenschutzes signifikant zu reduzieren.

Im Projekt wurden von den Verbundpartnern insgesamt sieben Demonstratorfahrzeuge eingesetzt. Dabei wurden diese zur Gewinnung von Testdaten als auch zur Validierung der in den APs erarbeiteten KI-basierten Lösungen verwendet.

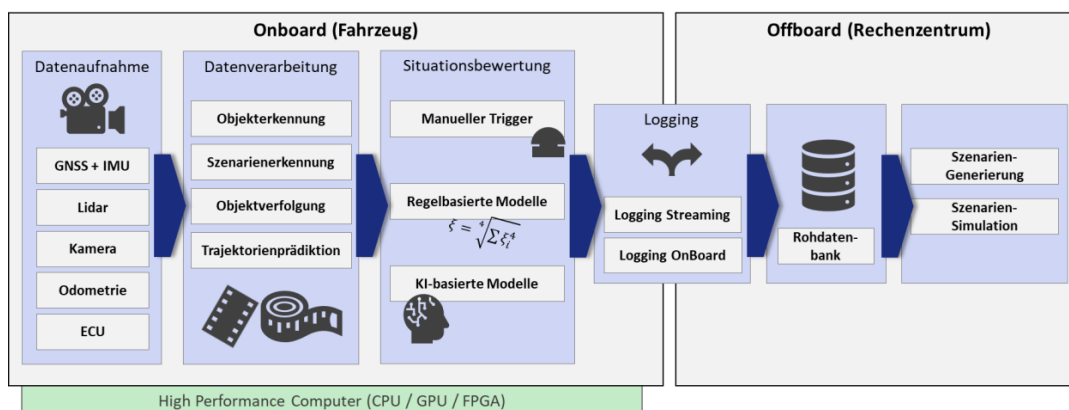


Abbildung 1 Erarbeiteter Datenfluss im Projekt KIsSME (KIsSME-Pipeline)

Das Teilvorhaben „Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien“ war zentraler Bestandteil des Verbundprojektes. Zur Erfüllung des Teilvorhabens wurde ein Demonstrationsfahrzeug aufgebaut, Testdaten eingefahren, KI-basierte Objekt- und Szenarienerkennungsalgorithmen entwickelt und validiert, sowie durch intensiven Austausch mit Projektpartnern die Integration in die KIsSME-Gesamtlösung zu gewährleisten.

# 1 Kurzdarstellung

## 1.1 Aufgabenstellung

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

Zur Lösung der Datenmengen-Problematik wurde in vergangenen Forschungsprojekten bereits eine On-Board Selektion der Daten in Echtzeit adressiert. Dabei stellte sich aber die Frage, wie die Selektion der Daten, besonders der datenintensiven Sensor- und Umfeldmodelldaten, erfolgen soll und welche Verfahren dort zur Anwendung kommen.

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

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

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

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

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

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

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

besteht zudem die Möglichkeit einer erweiterten Erfassung von nicht Ego-Fahrzeug bezogenen kritischen Szenarien.

Der aktuelle Stand der Technik erlaubt eine konventionelle Verarbeitung von hochauflösenden LiDAR Sensordaten und darüber hinaus die Szenarien-Extrahierung lediglich im Offline-Modus. Die neuartigen Sensordaten erweitern das heutige Leistungsspektrum von Kamera-basierenden Systemen, ermöglichen neue Anwendungen von KI-Ansätzen und erhöhen die Robustheit und die Fahrsicherheit autonomer Fahrzeuge. Zusätzlich erfassen LiDAR Sensoren keine personenbezogenen Daten und stehen somit im Einklang mit den geltenden Datenschutzrichtlinien. Unter Berücksichtigung des Datenschutzes trägt eine Archivierung und Bereitstellung der durch die KI extrahierten Testszenarien in standardisierten Formaten nachhaltig zu einem enormen Effizienzgewinn bei.

Die Aufgabe für LiangDao im Teilvorhaben „Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien“ war die Entwicklung von echtzeitfähigen, KI-basierten Algorithmen zur Objekt- und Szenarienerkennung auf Grundlage von LiDAR-Rohdaten, sowie die Sicherstellung der Kompatibilität zu anderen Softwarekomponenten der KISME-Verarbeitungskette, des Weiteren KISME-Pipeline genannt, sowie die Sicherstellung der Einhaltung von ASAM-Standards und DSGVO-Vorschriften.

## 1.2 Voraussetzungen des Vorhabens

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

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

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

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

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

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

### **Neuartige Testverfahren für die Validierung und Freigabe**

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

### **Verbesserte Umfelderfassung, -interpretation und Manöverplanung für die Erprobung**

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

### 1.3 Planung und Ablauf des Vorhabens

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

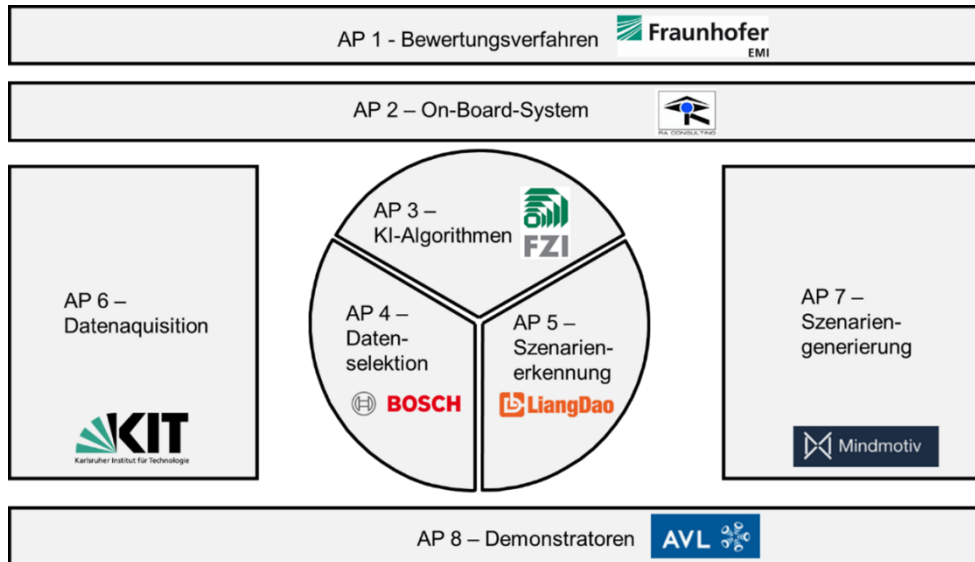


Abbildung 2: Struktur und Schnittstellen der Arbeitspakete im Projekt KIsSME

#### **AP1 – Bewertungsverfahren (Leitung Fraunhofer Institut für Kurzzeiddynamik)**

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

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

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

#### **AP3 – KI-Algorithmen (Leitung FZI Forschungszentrum Informatik)**

Adaption von KI-basierten Algorithmen zur echtzeitnahen Anwendung

#### **AP4 – Datenselektion (Leitung Robert Bosch GmbH)**

Kriterien zur Datenselektion relevanter Situationen durch Vorhersageabweichung

#### **AP5 – Szenarienerkennung (Leitung LiangDao GmbH)**

Entwicklung KI-basiertes Verfahrens zur Erkennung relevanter Szenarien

#### **AP6 – Datenakquisition (Leitung Karlsruher Institut für Technologie)**

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

#### **AP7 - Szenariengenerierung (Leitung Mindmotiv GmbH)**

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

#### **AP8 – Demonstratoren (Leitung AVL Deutschland GmbH)**

Validierung der Ergebnisse an Demonstratoren

#### **AP9 – Projektmanagement (Leitung AVL Deutschland GmbH)**

Interne und externe Zusammenarbeit, Verbreitung der Ergebnisse

Wie Abbildung 2 zu entnehmen, oblag LiangDao die Leitung von AP5 – Szenarienerkennung. Dieses AP mit seinen Zielen war auch das Hauptaugenmerk von LiangDao. Aufgrund des ganzheitlichen Ansatzes des Projektes, war LiangDao jedoch bis auf AP4 in allen Arbeitspaketen des Vorhabens vertreten, teils um weitere Arbeiten für die in AP5 vorgesehene Realisierung der echtzeitfähigen Objekt- und Szenarienerkennung- Algorithmen zu leisten, teils um die Kompatibilität der einzelnen Komponenten der KIS-SME-Pipeline sicherzustellen (Für eine detaillierte Darstellung der allgemeinen und spezifischen Arbeiten von LiangDao siehe 2.1 Verwendung der Zuwendung und erzielttes Ergebnis.)

## 1.4 Wissenschaftlicher und technischer Stand

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

Die nachfolgende Darstellung beschreibt den relevanten Stand der Technik zu Projektbeginn für die verschiedenen Komponenten der KIS-SME-Pipeline:

### Formalisierte Darstellung von Automotive Szenarien und Manövern

Die zunehmende Komplexität der Automatisierung von Fahrzeugassistenzsystemen (FAS), automatisierten Fahrfunktionen (AFF) bis hin zum autonomen Fahren selbst, stellt eine enorme Herausforderung an Entwicklungs- und Validierungskonzepte dar. Während klassischerweise vor Marktzulassung eines neuen Fahrzeugmodells oder einer neuen Fahrzeugkomponente die erfolgreiche Absolvierung einer vorgegebenen Anzahl an Testkilometern notwendig ist, kann ein kilometerbasierter Ansatz zum Sicherheitsnachweis von FAS/AFF nicht mehr ökonomisch erbracht werden. Dieses radikale Umdenken in der Automobilbranche und die damit verbundenen Schwierigkeiten und Unsicherheiten spiegeln sich in Forschungsprojekten wie PEGASUS [1], SET Level 4to5 [2], VV-Methoden [3] oder Industrieinitiativen wie u. a. die P.E.A.R.S. Initiative [4], OpenPASS [5] oder OpenADx [6] wider.

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

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

### Event Data Recording

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

verwendeten traditionellen algorithmischen und regelbasierte Ansätze zur Datenselektion skalieren aufgrund der enormen Datenmenge sowie einer sich kontinuierlich verändernden Datenlage absehbar nicht ausreichend, um diesen Anstieg aufzufangen. Diese Herausforderung gilt besonders für Entwicklung und Erprobung, und längerfristig auch für

den Betrieb der Fahrzeuge im Sinne der Produkthaftung, der nach rechtlichen Klärungen auch genutzt werden könnte, um potentiell fehlende Szenarien für die Entwicklung und (Langzeit-) Validierung der HAD/AD-Systeme bereitzustellen.

### **Szenariengenerierung**

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

### **Umfeldererkennung (am Beispiel LiDAR-Sensoren)**

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

### **Prädiktionsverfahren**

Automatisiertes Fahren im urbanen Umfeld stellt hohe Anforderungen insbesondere an Prädiktionsansätze zur Bewegungsvorhersage anderer Verkehrsteilnehmer dar, klassische modellbasierte Ansätze gelangen auch schon in einfachen Verkehrssituationen an ihre Grenzen. Die Bewertung der Güte der eingesetzten Ansätze erfolgt häufig nur anhand exemplarischer und vereinfachter Situationen ohne Betrachtung von Rückkopplungseffekten in der Signalverarbeitungskette. Eine Konzeption von Bewertungsansätzen, welche die Beobachtung von Bewegungspfaden anderer Verkehrsteilnehmer im Fahrzeugumfeld automatisch gegenüber den eingesetzten KI-Modellen vergleicht und daraufhin eine Selektion der Daten der aufgezeichneten Umgebungsdaten durchführt, wurde bislang nicht nachgewiesen. Hierfür sollen im Vorhaben multimodale, interaktionsbasierende Prädiktionsverfahren [7], [8] umgesetzt und auf die Anwendung im Versuchsträger erweitert werden.

### **Simulativ-ingenieurtechnisch Echtzeit-Bestimmung der Kritikalität von Szenarien (OnBoard)**

Grundlage für die Bestimmung der Kritikalität von Situationen im Straßenverkehr bilden definierte Kritikalitätsmetriken [9]. Für eine Echtzeitbestimmung der Kritikalität von Situationen im Straßenverkehr wird zudem eine Bewegungsprädiktion von Ego- und Objektfahrzeugen benötigt. Diese kann durch die Aufnahme der aktuellen Dynamik der betrachteten Situation, durch bekannte Bewegungsmuster umgebender Fahrzeuge und des Ego-Fahrzeugs selbst und/oder der Identifikation der Situation, in der sich das Ego-Fahrzeug befindet, durch Abgleich zu früheren Situationen, realisiert werden [10].

Es wird zwischen deterministischen und probabilistischen Metriken zur Bewertung der Kritikalität unterschieden. Die Auswahl der jeweils zu verwendenden Metrik hängt von der angestrebten Bewertung und Definition der Kritikalität selbst ab [10]. So erlauben es die Metriken Distance-of-Closest-Encounter (DCE) und Time-to-Closest-Encounter (TTCE) [11] auch eine Bewertung von unfallfreien Situationen, während andere Metriken nur Situationen als kritisch bewerten, die einen Unfall zur Folge haben. Deterministischen Metriken mit dem Ziel Unfälle vorherzusagen, werden allgemein auch als TTX-Metriken bezeichnet.

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

Durch Software-in-the-Loop (SiL) Simulationen und Hardware-in-the-Loop (HiL) Echtzeitrechner werden bereits Parameter von Situationen im Straßenverkehr aufgenommen und in Echtzeit derart verändert, dass eine so neu entstehende Situation im folgenden Verlauf durch die angewandte Definition von Kritikalität, als kritisch eingestuft worden wäre. Berechnet werden diese veränderten Parameter durch die oben benannte SiL Simulation. Fahrassistenzsysteme können so in den erzeugten kritischen Situationen getestet werden [12]. Real auftretende kritische Situationen, die Ursache von kritischen Situationen oder die Untersuchung der Sinnhaftigkeit der so generierten kritischen Situationen werden dabei zunächst nicht berücksichtigt. Die Anwendung einer künstlichen Intelligenz zur automatisierten Generierung ähnlicher kritischer Situationen auf der Basis real aufgenommener kritischer Situationen verspricht jedoch validere Ergebnisse bezüglich der Abdeckung aller relevanten kritischen Situationen. Dieser Ansatz wird nach bisherigen Recherchen vom State-of-the-Art nicht bedient.

Dies gilt umso mehr, wenn Szenarien abstrakt unter Verwendung von ASAM OpenX Standards dargestellt werden, d.h. Szenario-Variationen vergleichsweise generisch ausfallen müssen im Gegensatz zur Variation von Parametern festgelegter Szenariomodelle. Dies steht im Gegensatz zu ersten Ansätzen zur Verwendung von KI zur besseren Testabdeckung, die unter dem Begriff Design of Experiment bereits vermarktet wird [13].

In den vergangenen Jahren hat sich die Fähigkeit von generativen KI-Algorithmen wie Variational Autoencoders oder GANs (Generative Adversarial Networks), welche basierend auf bestehenden Daten neue und ähnliche Daten generieren können, stark verbessert. Insbesondere die Erzeugung von täuschend echt aussehenden 2D-Bildern z.B. von Personen hat durch den Einsatz weiterentwickelter GANs wie StyleGAN [14] große Fortschritte gemacht.

Für Bilddaten können diese Verfahren für die Erzeugung von neuen Fahrscenarien eingesetzt z.B., um Bilder mit unterschiedlichen Witterungsverhältnissen zu erzeugen [15], [16]. Die meisten dieser Verfahren beschränken sich jedoch meist auf 2D-Bilddaten und die Übertragung auf andere Datenarten stellt eine Herausforderung dar. So können beispielsweise LiDAR-Daten derzeit nur vereinzelt mithilfe dieser Verfahren erzeugt werden [17], da viele generative Algorithmen nicht auf Punktwolken ausgelegt sind. Ähnliches gilt für die Erzeugung der Daten weiterer Sensoren eines autonomen Fahrzeugs, um alle Daten bei der Szenengenerierung abzudecken. Für Sensoren, die eine physikalische Messgröße über

Zeit aufnehmen, wären generative Algorithmen für die Synthese von Zeitreihen ähnlich wie bei [18] denkbar.

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

### **Standardisierungsaktivitäten im Bereich ADAS Simulation**

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

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

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

Beziehungen aus der Kernontologie verwenden, um klare und eindeutige, logisch basierte Definitionen für die Sprachbegriffe bereitzustellen.

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

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

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

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

## **1.5 Zusammenarbeit mit anderen Stellen**

### **Zusammenarbeit mit anderen Projekten**

Der Austausch mit Projekten, die sich in Teilen mit ähnlichen Fragestellungen beschäftigten, wurde eine hohe Relevanz beigemessen. Daher wurde ein enger Austausch praktiziert. Dies war bereits dadurch gewährleistet, dass stets mindestens ein KIsSME-Partner auch in den anderen Projekten mitgearbeitet hat. Im nationalen Raum waren insbesondere die Projekte VVMethoden [3], SETLevel [2] und AVEAS [19] von besonderer Bedeutung.

### **Zusammenarbeit mit anderen Firmen/Einrichtungen**

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

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

Dieser Austausch trug wesentlich dazu bei, dass während der Laufzeit des Projekts KIsSME der aktuelle Stand der Technik eingebracht wurde.

## 2 Eingehende Darstellung

### 2.1 Verwendung der Zuwendung und erzielttes Ergebnis

In der folgenden Tabelle sind, die zu Projektbeginn definierten, wissenschaftlichen bzw. technische Arbeitsziele des Vorhabens dargestellt.

<b>Teilziel 1 - KI Algorithmen für On-Board Datenakquisition</b>	
Beiträge	Sensorik und Sensordatenfusion Echtzeitnahe Aufbereitung: Erkennung, Reduktion Streamen in Cloud Kritikalitätserkennung / Szenarienerkennung Daten für Szenarienerstellung vorbereiten Vorarbeit für KI-basiertes Event-Data-Recording
Bewertung	Veränderung zum Stand der Technik / Steigerung TRL Nachweis am realen Demonstrator
<b>Teilziel 2 - KI Algorithmen zur Datenauswertung</b>	
Beiträge	Prädiktion der Verkehrssituation und Vergleich gegenüber Ground Truth Objekterkennung aus LiDAR Ad-Hoc Szenariensextraktion Ad-Hoc Simulation
Bewertung	Veränderung zum Stand der Technik / Steigerung TRL Nachweis am realen Demonstrator
<b>Teilziel 3 - KI Algorithmen für Off-Board Datenverarbeitung</b>	
Beiträge	Rekonstruktion des erfassten Szenarios Klassifikation de Elemente des erfassten Szenarios Kritikalitätsbewertung / Szenariengenerierung Digital Twin des realen Szenarios für KI-Training
Bewertung	Veränderung zum Stand der Technik / Steigerung TRL Nachweis am realen Demonstrator
<b>Teilziel 4 - Hohe Güte der relevanten kritischen Szenarien in Datenbank</b>	
Beiträge	KI-Algorithmus zur Verbesserung der Kritikalitätskriterien Resimulation/Validierung mit effizienten Tools Nutzung komprimierter Fahrdaten im Entwicklungsprozess
Bewertung	Steigerung TRL Nachweis am realen Demonstrator / Reduktion Kosten und Zeit

Die Eigenevaluation der Projektergebnisse erfolgte anhand von Leistungsindikatoren (KPI), welche für die technischen Entwicklungsarbeitspakete (AP1-AP5, AP7) definiert wurden und anhand der während der Erprobungsfahrten (AP6) erhobenen Daten aus den Demonstratoren (AP8) überprüft werden. Die exakte Definition der KPI-Kriterien in ihrer Anwendung sowie die Methodik zur Ermittlung der Basiswerte und des Status Quo als Metrik des Projektfortschritts wurde in den ersten sechs Monaten der Arbeitspaktlaufzeit im Verbund mit den weiteren Partnern anhand von Datensätzen und Use-Cases detailliert. Die Basiswerte wurden bis Ende Monat 6 der Laufzeit des jeweiligen Arbeitspakets definiert. Der Grad der Erfüllung der KPIs (Fortentwicklung des Status quo von Basiswert zu Zielwert) wurde kalenderhalbjährlich dokumentiert und mit Erwartungswerten für die nächsten 6 Monate belegt. Ein projektweites Controlling und Risikomonitoring überwachte die Varianz zwischen Erwartungswert des KPI-Fortschritts und Status quo und definierte Maßnahmen zur Abschwächung der Auswirkung bei verfehlten KPI-Zielen und führte diese der Projektsteuerung zu. Die Überwachung oblag dabei vor allem den Leitern der jeweiligen Arbeitspakete. Dabei wurden von den Verbundpartnern KPI in folgenden Kategorien adressiert:

Indikator im Projekt KIsSME	Stand bei Projektbeginn	Ziel bei Projektende
<b>Effizienz:</b> Reduktion der zu speichernden Daten durch szenarienbasiertes selektives Logging (AP5).	Keine automatisierte Reduktion in Loggerprodukten	Demonstratorabhängig um bis zu 95% Reduktion.
<b>Performanz:</b> Durchschnittliche Latenz zwischen Datenerfassung und Verarbeitungsende bei bis zu 10 gleichzeitigen Sensorströmen wie Video, Radar, LiDAR (AP2, AP3).	Keine Klassifikation und Prädiktion in Loggerprodukten	Echtzeitnahes Klassifizieren und Prädizieren (Latenz < 5s)
<b>Datenschutz:</b> Automatisierte Identifikation von datenschutzrelevanten Szenarienelementen in komplexen Szenarien auf Einzelbildebene (AP1, AP2).	Einfache Identifikation von z.B. Kennzeichen oder Gesichtern erlaubt 50% durchschnittliche Genauigkeit	90% Treffergenauigkeit in komplexen Szenarien
<b>Qualität:</b> Genauigkeit der Prädiktion bzw. die Eintreffenswahrscheinlichkeit des vorhergesagten individuellen Verhaltens (AP3, AP4, AP5).	Keine KI-basierte Klassifikation und Prädiktion in Loggerprodukten	85% Eintreffenswahrscheinlichkeit
		90% der real auftretenden Szenarien werden richtig klassifiziert
<b>Erkenntnisgewinn:</b> KI-basierte Erkennung von komplexen Szenarien (AP6, AP7, AP8).	Keine KI-basierte Klassifikation und Prädiktion in Loggerprodukten	Erkennung von > 100 komplexer Szenarienerweiterungen basierend auf Testfahrtdaten
		Auffinden von > 10 neuen beispiellosen Szenarien

Im Projekt KIsSME wurden zusätzlich eine Evaluation mittels Technologiereifegrade (TRL) entsprechend den Vorgaben des Projektträgers verwendet:

Stufe	Definition
TRL 1	Beobachtung und Beschreibung des Funktionsprinzips
TRL 2	Beschreibung der Anwendung der Technologie
TRL 3	Nachweis der Funktionsfähigkeit der Technologie
TRL 4	Versuchsaufbau im Labor
TRL 5	Versuchsaufbau in (simulierter/ vereinfachter) Einsatzumgebung
TRL 6	Prototyp in (simulierter/vereinfachter) Einsatzumgebung
TRL 7	Prototyp im (realen) Einsatz
TRL 8	Nachweis der Funktionsfähigkeit im Einsatzbereich abgeschlossen
TRL 9	Technologie im Markt

Die Technologiereife der Forschung und Entwicklung im Projekt definierte sich insbesondere durch die in den Arbeitspaketen AP2-5 adressierte KI-basierte automotive-taugliche On-Board-Plattform (HW- und SW-Komponenten). Während der Vorhabenlaufzeit strebten die Partner eine TRL von 5-7 an, im direkten Projektanschluss wird durch eine zeitnahe Fortentwicklung eine TRL 9 zur Markteinführung angestrebt. Der aktuelle Reifegrad der Technologie ist oftmals nur durch erste Erprobungen von Technologiedemonstratoren unter Laborbedingungen geprägt. Nachfolgende Indikatoren erlaubten eine Bewertung, inwieweit die Teilziele erreicht wurden:

Technologiebereich im Projekt KIsSME	Bewertbare Teilziele	Projektbeginn	Projektende
KI-gestützte lernende Systeme zur selektiven Erfassung von Daten aus kritischen Szenarien im Fahrbetrieb auf On-Board Unit einsetzbar	Teilziel 1 Teilziel 2	TRL 3	TRL 5
Integriertes On-Board-System mit KI SW-Komponenten für echtzeitnahe Risikoerkennung und selektive Datenselektion	Teilziel 1 Teilziel 2	TRL 2	TRL 4
Integrierte automatisierte Anonymisierung für Datenschutz	Teilziel 4	TRL 2	TRL 4
HW-/SW-Komponenten für echtzeitnahe Umsetzung der KI-Algorithmen On-Board	Teilziel 1 Teilziel 2	TRL 4	TRL 6
Tool zur Generierung der Szenarienbeschreibung	Teilziel 3	TRL 4	TRL 5

In den folgenden Punkten sind die Ergebnisse der einzelnen Arbeitspakete aufgelistet. Zunächst allgemein für das Projekt KisSME, dann die Arbeiten von LiangDao für das Teilvorhaben „Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien“. Die Arbeiten für das Teilvorhaben waren dabei vor allem in dem von LiangDao geleiteten AP5 („Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien“) verortet.

### **2.1.1 AP1 - Bewertungsverfahren**

Ziel von Arbeitspaket 1 (AP1) - Bewertungsverfahren war es im Wesentlichen, die Grundlagen für ein Bewertungssystem zu schaffen, welches in der Lage ist Verkehrsszenarien aus der Ego-Perspektive eines Fahrzeugs bezüglich dessen Relevanz für eine Aufnahme zu bewerten. Die Relevanz von Fahrerszenarien wurde dabei an eine sicherheitskritische Bewertung angelehnt. In AP1 wurden zudem die rechtlichen Grundlagen für die datenschutzkonforme Verwendung der im Projekt verarbeiteten Daten identifiziert und kommuniziert. Während der parallelen Laufzeit, fand zwischen AP1 und AP4 ein vertiefter Austausch und eine enge Zusammenarbeit statt. Dieser adressierte vor allem die Definition des Relevanzbegriffs für das Vorhaben, die Identifikation notwendiger Metriken und die Identifikation initialer Szenarien bezüglich der angestrebten Relevanzbewertung.

Zentrale Ergebnisse aus AP1 bilden ein implementiertes, initiales System zur Bewertung von Verkehrsszenarien sowie Algorithmen zum KI-basierten Trajektoriensampling und der Anomaliedetektion. Diese dienen als Komponenten für die weitere Implementierung und Anwendung eines ganzheitlichen Bewertungssystems in AP2, AP4 und AP7.

In Teilarbeitspaket 1.1 (TAP1.1) - Vorgehensrahmen und umsetzbare Risiko- und Bewertungskriterien für Kritikalität und Auswahl von Szenarien wurde initial ein Vorgehensrahmen für die Relevanzbewertung von Szenarien basierend auf Methoden der Risiko- und Resilienzanalyse nach einem Resilienz-Management-Prozess aufbauend auf dem ISO-Standard 31000, sowie der STPA (Systems Theoretic Process Analysis) erarbeitet, vorgestellt und diskutiert. Als Grundlage für die szenariospezifische Relevanzbewertung wurden Beispielszenarien definiert, sowie eine Sammlung von über 100 Relevanz- und Kritikalitätsabhängiger Metriken erstellt. In Workshops wurden verschiedene Softwaretools für die Simulation von Fahrerszenarien und Sensorsystemen vorgestellt und diskutiert (u.a. esmini, CARLA RoadRunner, IPG Carmaker). Die Simulationsplattformen OpenPASS und PTV Vissim wurden detailliert besprochen und deren Einsatz im Projekt näher untersucht. Recherchen zu verschiedenen Datensätzen, sowie deren Eignung, Verfügbarkeit, Umfang und Zugänglichkeit dienten als Grundlage für die KI-basierte Szenarienbewertung und Generierung. Im Rahmen von TAP1.1 konnte in Kollaboration mit weiteren Projektpartnern das Paper „Framework for safety assessment of autonomous driving functions up to SAE level 5 by self-learning iteratively improving control loops between development, safety and field life cycle phases“ bei der Konferenz IEEE ICCP vorgestellt und in den Proceedings veröffentlicht werden.

Im Rahmen des TAP 1.2 - Analytische Szenarienbewertung: top-down und bottom-up konzentrierten sich die Arbeiten unter anderem auf die projektinterne Definition der Begriffe Szenario und Situation, sowie der exemplarischen konzeptionellen Anwendung von Time-to-X Kriterien auf abstrakte Szenarien durch vorab Simulationen. Basierend auf dem Vorgehensrahmen aus TAP1.1 und weiteren Diskussionen, unter anderem in den AP1-Regelmeetings, konnte ein konkreter Ablauf der Relevanzbewertung anhand der in der Metriksammlung definierten Metriken erarbeitet werden. Basierend auf dem erarbeiteten Schema zur Szenarienbewertung wurden mehrere Algorithmen zur zeitaufgelösten Auswertung der Metriken jedes Verkehrsteilnehmers basierend auf Fahrzeugtrajektorien realisiert. Für erste Relevanzbetrachtungen bewerteten die Partner ausgewählte Szenarien

nach realem Vorbild. Die Anwendung des metrikbasierten Bewertungsystems wurde in TAP 1.2 auf definierten, potentiell relevanten Szenarien simulativ getestet. Dazu wurden die definierten Szenarien zunächst im ASAM OpenDrive-Standard definiert und an die OpenPASS Simulationsumgebung übergeben. Die Metriken wurden auf den simulierten Trajektorien ausgewertet.

In TAP 1.3 - ASAM OpenX konforme Szenarien- und Manöverbeschreibung wurden mehrere Workshops organisiert, welche Einführungen in die OpenX-Standards und aktuelle Entwicklungen und anstehende Änderungen durch die ASAM beinhalteten. Dies bildet die Grundlage für die Untersuchung der ASAM OpenX Standards auf ihre Vollständigkeit bezüglich der Gefährdungs- und Risikobewertung. Weiter wurden im Rahmen des TAP 1.3 weitere konkrete Szenarien in den für die Simulation notwendigen OpenX-Standards generiert. Dafür fanden Ergänzungen der in TAP1.1 erstellten Metriksammlung um eine ASAM OpenX-Standard-Abdeckung statt. Ein zentraler Punkt von TAP1.3 bestand zudem in der Diskussion und Erarbeitung der OnBoard-Komponenten des Bewertungsystems und der Definition geeigneter Schnittstellen und Formate für den OnBoard-Datenfluss, als Grundlage für die Arbeiten in AP2.

In TAP 1.4 - OpenPASS basierte schnelle Off-Board simulative Vorab-Szenario Bewertung definierte das Konsortium in Zusammenarbeit mit TAP 1.2, TAP1.3 und AP4 weitere Szenarien zur Bewertung. Die Outputs der Simulationsumgebung wurden analog zu TAP 1.1 auf die Anschlussfähigkeit an die Berechnung von Metriken zur Relevanzbestimmung für jeden simulierten Agenten untersucht. Basierend auf den zuvor vorgestellten Vorgehensrahmen und initial umgesetzten Metrikimplementierungen wurden die definierten Abbildungen für eine ganzheitliche Kritikalitätsbewertung umgesetzt. Dazu wurde eine Normierung der Metriken in dimensionslose Einzelkritikalitäten vorgenommen. Die Normierung besteht dabei aus inversen und linearen Zusammenhängen zwischen Metriken und Einzelkritikalitäten, sowie der kumulativen Berechnung einer Gesamtkritikalität anhand von Einzelkritikalitäten über die p-Norm. So wurde ein konkreter, initialer Algorithmus zur ganzheitlichen Kritikalitätsbewertung von Fahrscenarien realisiert. Übergeordnetes Ziel war es entsprechend der Vorhabensbeschreibung ausgewählte Szenarien zu simulieren und diese ganzheitlich zu bewerten. Des Weiteren wurden ebenfalls aufgenommene Daten (TAP3.3 und AP6) und synthetisch erzeugte Daten (TAP1.5) bewertet. Zwölf der ursprünglich 100 Metriken wurden dabei als besonders relevant für die Bewertung identifiziert, da diese unter anderem die Eigenschaft aufweisen trajektorienbasiert und aus der Sicht des Ego-Fahrzeuges bewertbar zu sein.

In TAP 1.5 - Top-down (Off-Board) Szenariengenerierung mit generativen ML/KI-Ansätzen fand eine umfassende Recherche zu vorhandenen Datenquellen und deren Zugänglichkeit statt, welche als Trainingsdaten für die in TAP1.5 geplanten KI-Algorithmen geeignet sind. Dazu wurde in TAP 1.5 zudem ein TAP-übergreifender Fragebogen zur Abfrage des State of the Art erstellt. Die gesammelten Daten dienten als Grundlage für das Testen von Bewertungsmaßen und den Vergleich zu Simulationsergebnissen (Validierung). Geeignete identifizierte Datensätze sind die der levelXdata-GmbH, der Motion-Datensatz von Waymo, sowie der KITTI-360 Datensatz. Anschließend an die Literaturrecherche wurde testweise eine einfache GAN-Architektur implementiert und mit dem Datensatz von Waymo trainiert. Die so implementierte Pipeline diente zur Szenariengenerierung und wurde testweise auf die Eignung für Trajektorienprädiktion, sowie Anomaliedetektion hin untersucht. Für die beispielhafte Anwendung des trainierten GAN wurde das aufgenommene Überholmanöver ausgewählt, welches im Rahmen von AP6 als Szenario 5 bei den Versuchsfahrten am 01.12.2021 am Campus Ost des KITs durchgespielt wurde.

In TAP 1.6 Gesetzlichen Regelungen zum Datenschutz bei Erprobungsfahrten wurden die rechtlichen Grundlagen identifiziert, um datenschutzkonform Erprobungs- und Aufnahme-fahrten durch die im Projekt vorhandenen Demonstrator-Fahrzeuge durchzuführen.

## Arbeiten zum Teilvorhaben

Wie zuvor beschreiben diente Arbeitspaket 1 dazu die gemeinsam die Grundlagen für die Erstellung der KIsSME-Pipeline zu erarbeiten, auch um sicherzustellen, dass die Komponenten der verschiedenen Partner später zusammenpassen. LiangDao war daher in allen Teilarbeitspaketen involviert. Insbesondere erfolgten folgende Beiträge: Erarbeitung der Anforderungen Risiko-relevanter Szenarien-Elemente. Erarbeitung relevanten Kritikalitätsmetriken und erfassbarer Umfeldelemente, um die Vollständigkeit der Szenarienmodellierung sicherzustellen. Erarbeitung von per LiDAR erfassbaren Szenarien, die für den Katalog aufgenommen werden könnten. Anpassung von LiangDao-Objektlisten an ASAM OpenX-konforme Szenarien- und Manöverbeschreibung. Fit-Gap Analyse hinsichtlich der Umfeld-Elemente der OpenX Szenarienbeschreibung. Evaluierung von öffentlichen Datensätzen (Waymo, KITTI360) für das Training von KI-basierten Algorithmen, inklusive Prüfung, ob diese in ein bei LiangDao gängiges Format umgewandelt werden können. Nur der KITTI360-Datensatz erfüllte alle Anforderungen und wurde für das initiale Training der LiangDao eigenen KI-basierten Algorithmen verwendet. Bereitstellung von selbst eingefahrenen Testdaten in KIsSME-konformen Formaten an Partner, um Anforderungen und Potential von LiDAR-Daten zu verdeutlichen. Die bereitgestellten Daten dienten auch als erste eigene Trainingsdatensätze im Konsortium. Dazu zählten über 200 Einscher-Szenarien. Die Daten wurden unter den zuvor recherchierten Prinzipien für datenschutzkonforme Aufnahmefahrten aufgezeichnet und geteilt. Dazu wurden Testdaten von Partnern evaluiert (z.B. vom KIT) evaluiert und verarbeitet.

Außerdem wurde ein erstes LiDAR-Sensorkonzept für eine Onboard-Szenarienbewertung erstellt, welches dann im Rahmen von AP5 weiterentwickelt und implementiert wurde (siehe AP5)

### 2.1.2 AP2 – OnBoard-System

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

Im initialen Teilarbeitspaket TAP2.1 – Erstellung der Anforderungsspezifikation für das modulare und erweiterbare On-Board-System (OBS) zur selektiven KI-Methoden basierten Selektion und Erfassung von Daten – wurde das Konzept des OBSs, sowie die dazugehörigen Softwarekomponenten und die Hardwarekomponenten mit Projektpartner abgestimmt. Zu diesem Zweck sammelte und überarbeitete das Konsortium die für das Referenzsystem benötigten funktionalen Anforderungen und legte die damit verbundene Menge an funktionalen Komponenten fest. Weiterhin wurden verschiedene Systemarchitekturen und Protokolle zum Datenaustausch von Fahrzeugrohdaten und Sensordaten verglichen, um eine exemplarische Architektur für das Referenzsystem abzuleiten. Daraus ist eine Beispielarchitektur für ein Referenzsystem entstanden, die auf mehreren der verfügbaren Demonstratoren und Messfahrzeugen von AP3, AP5 und AP6 benutzt wurde. Zur generischen Erfassung von Messdaten aus Fahrzeugen wurde ein eingebetteter Mess- und Kalibrierserver (EMC-Server) konzipiert und spezifiziert. Mit der verwendeten Service-Orientierte Architektur (SOA) wurde hierbei der Wert auf Modularität, Erweiterbarkeit und Standardisierung gelegt.

Die Anforderungsspezifikation für das OBS und die Beispielarchitektur für das Referenzsystem liefert die Ausgangsbasis für TAP 2.2 – Entwicklung von Konzepten von Systemarchitekturen und Trigger für das selektive Erfassen in einem konfigurierbaren System zur On-Board Echtzeit-Fahrüberwachung. In diesem TAP wurde die Auslegung des OBSs und der zugeordneten Komponenten fortgesetzt. Weiterhin wurden die Schnittstellen zwischen den Komponenten und die Abdeckung durch die verschiedenen Partner identifiziert und abgestimmt. Bspw. wurde der Industriestandard Robot Operation System (ROS) als Schnittstelle zur Übertagung von Rohdaten für die Situationsbewertung herangezogen.

Die Ablaufsteuerung mit Open Test Sequence eXchange (OTX) bezieht sich konzeptgemäß auf die Schnittstelle des Loggers und die Schnittstelle zur Datenübertragung zu den OffBoard-Komponenten und dient als Erweiterung zur Messwertauswahl. Die Auslösemechanismen (Triggers), die die Aufzeichnung der Messdaten in Abhängigkeit von der aktuellen Fahrsituation initiieren, wurden in verschiedenen Kategorien (manuell, KI-basiert und regelbasiert) untersucht und jeweils konzeptionell erfasst. Als Ergebnis wurde eine Systemarchitektur des Referenzsystems entwickelt, das als Ausgangspunkt für die Demonstratoren verwendet wurde. (M2.1 Festlegung Systemarchitektur). Daneben wurden standardisierten Formate für die aufgezeichneten Daten evaluiert (z.B. ASAM OpenDRIVE und ASAM OpenSCENARIO), die für den Datenaustausch zwischen den erzeugten Fahrzeugdaten und den Daten für die Off-Board-Simulation und die Generierung von Szenarien geeignet sind.

Die entworfene Systemarchitektur, die identifizierten Komponenten und die assoziierten Schnittstellen sowie die Standardisierungen wurden in dem TAP 2.3 – Entwicklung eines heterogenen und gekoppelten echtzeitfähigen Datenloggings, bestehend aus HW- und SW-Komponenten für die echtzeitnahe Erfassung der Messdaten mit bereits existierendem standardisiertem Verfahren – sowie dem TAP 2.4 – Entwicklung und Integration eines High Performance Computer basierten Systems (Hardware und Software) für die echtzeitnahe selektive Erkennung von kritischen Situationen und Erfassung von Daten aus dem Fahrzeug – zur Umsetzung und Integration des OBSs verwendet. Die beiden TAPs umfassten sowohl die prototypische Umsetzung der ausgelegten Komponenten des OBSs als auch die

Auswahl eines SW-Frameworks und einer Austauschplattform, um den Austausch von Softwarekomponenten zu fördern und die Entwicklungszusammenarbeit zwischen verschiedenen Partnern zu erleichtern. An der Stelle wurden die Workshops für ROS und Docker-Container organisiert. Als einheitliches integriertes SW-Framework wurde das ROS v1 und als SW-Austauschplattform das praxisbewährte Docker gewählt, um Austauschbarkeit, Modularität und plattformübergreifende Hardware-Kompatibilität der Entwicklung zu gewährleisten.

Durch die prototypische Implementierung der im Rahmen AP7 ausgelegten Streaming-Komponente, die als Vermittlungskomponente zwischen OnBoard- und OffBoard-System dient, der OTX-Komponente und der Topic-Mapping-Komponente, die die in den Demonstratoren verwendeten proprietären Messageformate auf standardisierte Formate abbildet, wurde das funktionstüchtige OBS mit Basisfunktionalität zur Verfügung gestellt und konnte im Anschluss von den anderen Projektpartnern getestet werden. (M2.2 Datenlogging System für Erfassung von ADAS-Messdaten).

Das Situationsbewertungssystem wurde mit regelbasierten (daher Metriken-basierten) und Datenbasierten (daher KI-basierten) Ansätzen realisiert. Zur Umsetzung des Metriken-basierten Ansatzes im OBS wurde die im AP1 und AP4 entwickelte Methodik zur Kritikalitätsbewertung und die vom AP5 bereitgestellten verarbeiteten Sensordaten aus Testfahrten verwendet. Im Hinblick auf den KI-basierten Lösungsansatz wurden die von AP6 generierten Simulationsdaten zum Trainieren des maschinellen Lernmodells zusätzlich zu den realen Testfahrt Daten benutzt. Hierbei wurden die klassischen ML-Methode und die Deep-Learning-Algorithmen auf Basis des Trainingsdatensatzes mittels KI-Frameworks (Scikit-learn und TensorFlow) im Off-Board benutzt. Die resultierenden Modellvarianten wurden als SW-Komponenten mit ROS-Umgebung im OBS integriert und evaluiert. Die Implementierung der jeweiligen Komponenten mit Docker-Container und die Umsetzung vom Situationsbewertungssystem mit verschiedenen Lösungsansätzen erweiterten den Funktionsumfang des OBSs zur selektiven Erfassung der Messdaten (M2.3 Datenlogging System für Selektion von Szenarien) und bildet die Grundlage für die weitere Optimierung der Performance auf der HPC-Einheit, nämlich TAP2.5 – Integration und Betrieb: On-Board HPC-Unit in das elektronische Netzwerk verschiedener Fahrzeuge.

Im TAP2.5 wurde die Ausführung des neuronalen Netzes zur Kritikalitätsbewertung im On-Board-System systematisch bewertet und diverse Ansätze zur Optimierung der Inferenzleistung durchgeführt. Hierbei wurde die Optimierung durch die Einführung der TensorFlow mit GPU-Konfiguration, die Implementierung des leichtgewichtigen Inferenz-Frameworks TFLite und des damit verbundenen FlatBuffers-Modellformats, die Verwendung der von AP3 entwickelten dedizierten Beschleunigungseinheit mit quantisierten Modellen erreicht. Insgesamt kamen hier von den Partnern verschiedene Ansätze für die Situationsbewertung zum Einsatz, die auch gut unterschiedliche Verwendungsmöglichkeiten für KI-Methoden darstellen.

### **Arbeiten zum Teilvorhaben**

LiangDao hat für KisSME einen Versuchswagen aufgebaut, der sowohl dem Sammeln von Testdaten als auch Plattform für das Testen und Validieren der entwickelten Systeme diene. In AP2 beteiligte sich LiangDao daher an TAP 2.1, um eine Anforderungsanalyse für einzelner Komponenten durchzuführen, und entsprechende auf dem Markt verfügbare Systeme hinsichtlich der gefundenen Anforderungen zu evaluieren, für das Ergebnis siehe AP5. Außerdem wurde mit den Partnern in TAP 2.1 durch eine Schnittstellenspezifikation sichergestellt, dass alle Softwarekomponenten der verschiedenen Partner zueinander kompatibel sind und miteinander kommunizieren können. Nach der Sicherstellung der Kompatibilität erfolgten die weiteren Arbeiten zum Aufbau des LiangDao-Versuchswagens in AP5. An den TAPs 2.2-2.5 war LiangDao nicht beteiligt.

### 2.1.3 AP3 – Algorithmen

AP3 entwickelte einen Baukasten, bspw. Bibliotheken, Proof-of-Concept-Realisierungen sowie Best-Practices, von Software- und Hardwarekomponenten sowie deren Architekturintegration zur echtzeitfähigen Umsetzung von Algorithmen der künstlichen Intelligenz (KI). Ziel war insbesondere die Umsetzung rechenintensiver auf KI beruhender Algorithmen im Fahrzeug zur Erkennung und Bewertung von Szenarien.

Hierzu stimmten sich die Projektpartner im initialen TAP 3.1 - Anforderungsanalyse bzgl. Echtzeitfähigkeit der KI-Algorithmen aus AP4 und AP5 sowie des Bewertungssystems aus AP1 und Kriterien zur Bewertung – über Anforderungen an die Architekturintegration, die Datenverarbeitungspipeline und davon abgeleitet an die Software- und Hardwarekomponenten ab. Hierzu wurden die angestrebten Systemarchitekturen der Partner diskutiert, welche im Kern einer ähnlichen Verarbeitungspipeline folgten und lediglich die einzelnen Verarbeitungsschritte bzw. deren Reihenfolge anwendungsspezifisch war. Aus diesem Grund wurde eine abstrahierte Systemarchitektur basierend auf der System-Theoretic Process Analyse (STPA) erstellt. Diese bildete die Basis zur Ableitung und Diskussion von Echtzeit- und Architektur Anforderungen.

Diese abstrakte Architekturspezifikation sowie die funktionalen, algorithmischen Anforderungen aus den Arbeitspaketen AP1, AP4 und AP5 bildeten die Basis für TAP 3.2 - Entwurf der Bibliothekskomponenten für KI-Algorithmen im agilen Co-Design. In diese TAP wurden verfügbare Software- und Hardwarekomponenten identifiziert und bzgl. ihrer Eignung für die Umsetzung der Funktionen, bspw. einer LiDAR- und kamerabasierten Objekterkennung, einer KI-basierte Szeneninterpretation oder einer Bewegungsvorhersage/-prädiktion von Verkehrsteilnehmern, evaluiert. Hierbei wurden für die Hardware unterschiedliche Beschleunigerkonzepte evaluiert, wohingegen bei der Software, vorrangig KI-Methoden, bzw. KI-Architekturen evaluiert wurden. Bei den Beschleunigerkonzepten wurde bspw. der NVIDIA Deep Learning Accelerator oder Gemini Accelerator evaluiert. Auf Softwareseite wurden unterschiedliche Convolutional Neural Networks (CNN) zur Bildklassifikation sowie Generative Adversarial Network Ansätze zur Prädiktion untersucht. Schnittstelle bildete die Betrachtung unterschiedlicher KI-Frameworks zur Implementierung der Algorithmen und zum Deployment. Diese Arbeiten resultierten in applikationsspezifische SW- als auch HW-Komponenten für KI-Funktionalitäten (Meilenstein M3.1).

Diese identifizierten, angepassten bzw. erweiterten Bibliotheken, PoC-Realisierungen sowie Best-Practices wurden in dem TAP 3.3 - Umsetzung der unterschiedlichen echtzeitfähigen Algorithmen zur KI-basierten Bewegungsvorhersage/-prädiktion – sowie dem TAP 3.4 - Echtzeitnahe Umsetzung der KI-Algorithmen zur Szenarienerkennung und Evaluation mit AP6-Testdaten – zur Umsetzung der Datenverarbeitungspipelines und die Integration in die übergeordnete Systemarchitektur genutzt. Dies umfasste, neben der Konzeption der Datenanbindung, hier sowohl on- als auch off-board, insbesondere die Portierung unterschiedlicher Modelle des maschinellen Lernens (ML) sowohl auf angepasste SoC-Architekturen (FPGA, RISC-V) sowie auf Commercial-off-the-shelf-Systemen (NVIDIA Xavier). Des Weiteren wurden hybride Ansätze, d.h. die Kombination von ML-Modell und symbolischer KI, umgesetzt. Mit Hilfe der identifizierten Techniken konnte bspw. eine LiDAR-basierte Objekterkennung mit einer Latenz von unter 100ms umgesetzt werden sowie eine kamerabasierte Objekterkennung mit einer Spitzenleistungsaufnahme von unter 10W. Des Weiteren wurde eine objektbasierte Anomaliedetektion umgesetzt, welche 20 Trajektorien pro Sekunde sampeln und auf Anomalie/Kritikalität bewerten kann. Bei der Datenanbindung wurden beispielsweise ROS-Schnittstellen zur einfachen Integration in den Fahrzeugen sowie an einer nahtlosen Integration der KI-Algorithmen in das übergeordnete Logging- und Aufzeichnungskonzept realisiert. Diese Implementierungen bildeten in der ersten Entwicklungsphase effiziente, echtzeitnahe Realisierung der entwickelten KI-basierten

Algorithmen (Meilenstein M3.2). Schwerpunkt des TAP 3.4 stellte die Optimierung und Evaluation der Algorithmen dar. Hierbei wurden neben der Optimierung der Hardware- und Softwarekomponenten aus TAP 3.2 insbesondere das Zusammenspiel von Software- auf Hardwarekomponenten verbessert. Diese Optimierungen ermöglichen die oben genannten Leistungswerte zu erreichen. Begleitet wurden diese Optimierung und Systemumsetzung durch simulationsgestützte Ansätze zur Analyse einer szenarienabhängigen Echtzeitbewertung, bspw. zur Anomaliedetektion in LiDAR-Daten. Neben den AP6-Testdaten stellten diese Simulationen eine wichtige Säule zur Bewertung der Umsetzungen dar.

In TAP 3.5 - Proof-of-Concept für die Anonymisierung von personenbezogenen Daten - wurden die im Projekt diskutierten und im Rahmen der Versuchsfahrten angewendeten Anonymisierungskonzepte generalisiert und im Kontext der entwickelten Algorithmen bewertet. Zusammen mit TAP 3.4 bilden diese Ergebnisse die abschließende Optimierung der HW/SW-Systems und Methoden zur Anonymisierung von Daten (Meilenstein M3.3). Die entwickelten Systeme wurden im Rahmen von AP8 in unterschiedliche Versuchsträgern integriert und erprobt.

### **Arbeiten zum Teilvorhaben**

AP3 beschäftigt sich im Allgemeinen mit der Adaption von KI-basierten Algorithmen zur Echtzeitnahen Anwendung. LiangDao nutzte TAP3.1, um mit Input der Partner eine eigene Anforderungsanalyse für echtzeitnahe Objekt und Szenarienerkennung zu erstellen, und ein erstes Konzept für die Umsetzung zu erarbeiten. Die weiteren Arbeiten erfolgten wie beim OnBoard-System (AP2) in AP5.

LiangDao war außerdem in TAP3.5 vertreten, um die schließlich entwickelten KI-Komponenten hinsichtlich datenschutzrelevanter Kriterien zu bewerten. Die entwickelten KI-basierten Objekt und Szenarienerkennungsalgorithmen verarbeiten im Versuchsfahrzeug von LiangDao alleine LiDAR-Rohdaten, sowie unterstützend Zustandsdaten des Egofahrzeugs. Damit werden zu keinem Zeitpunkt datenschutzrelevante Umgebungsdaten erfasst, noch verarbeitet oder ausgegeben. In LiDAR Rohdaten (Punktwolken, siehe AP5 für Beispiele) können die Algorithmen zwar Fahrzeuge und Personen erkennen, allerdings ist die Auflösung der Punktwolke im Vergleich zu Kameradaten sehr gering und den Punkten fehlt es an Farbinformationen, nur Intensitäten werden erfasst. Daher enthalten die verwendeten LiDAR-Punktwolken nicht genug Informationen, um etwa KFZ-Kennzeichen auszulesen oder Personen anhand ihrer Gesichtsmerkmale oder sonstiger Merkmale zu identifizieren, weder per Algorithmus noch per menschlichem Auge. Die Verarbeitungskette ist daher inhärent von Beginn an datenschutzkonform.

Diese Einschätzung wurde durch ein Schreiben der Landesbeauftragten und Informationsfreiheit Nordrhein-Westfalen vom 14.9.2022 bestätigt. Bei der Verwendung von rein LiDAR basierten Systemen „Zur Verkehrserkennung... ..würden sie sogenannte LiDAR-Sensoren verwenden. Anhand der übersandten Links konnte ich keine Erhebung personenbezogener Daten feststellen. Gegen den Einsatz der Sensoren kann ich somit keine datenschutzrechtlichen Bedenken geltend machen. „[20].

#### 2.1.4 AP4 – Datenselektion

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

Im Rahmen des AP4 wurden zunächst gemeinsam mit AP1 die Metriken festgelegt, die geeignet sind, kritische Fahrsituation zu bewerten und zu erkennen, sowie Ergebnisse zur Szenarienbewertung aus AP1 in AP4 in Anwendung gebracht und verstetigt. Dazu wurden die benötigten Datenquellen identifiziert und eine adäquate Bereitstellung der Messdaten für die Software-Module zur Metrikberechnung sichergestellt. Daneben wurden KI-basierte Metriken entwickelt, die auf Basis der Trajektoriendaten der in der Fahrzeugumgebung erkannten anderen Fahrzeuge die Kritikalität der Fahrsituation beurteilen.

Als erste einfache Metrik wurde in AP4 der Prediction-Monitor entwickelt. Dieser überwacht die Prädiktion für die zukünftige Bewegung erkannter Fahrzeug- und Fußgängerobjekte, und vergleicht diese mit der dann tatsächlich ermittelten Position. So kann erratisches, nicht der Prädiktion entsprechendes Verhalten erkannt werden. Diese Metrik wurde dabei sowohl im Labor als auch in den Versuchsfahrzeugen implementiert und getestet. Eine Visualisierung der Prädiktionsabweichung wurde im Rahmen eines Demonstrators ebenfalls implementiert. Eine weitere Metrik ist der Suspicious Driving Monitor, der das Verhalten anderer Verkehrsteilnehmer beobachtet und bewertet. Dabei wird mithilfe eines neuronalen Netzes die Trajektorie jedes Fahrzeug- und Fußgängerobjekts über eine Encoder-Decoder-Architektur (Conditional Variational Auto-Encoder, CVAE) analysiert. Auf diese Weise kann unabhängig von der aktuellen Umgebung normales und verdächtiges Verhalten unterschieden werden. In einem weiteren Ansatz wurde über ein Zusammenspiel mehrerer neuronaler Netze nach dem Vorbild der Generational Adversarial Networks (GANs) eine Architektur entwickelt, mit der normale und unnormale Trajektorien unterschieden werden können. Hierbei entwickelt ein neuronales Netz Fahrzeugtrajektorien, die dann von einem anderen Netz bewertet werden. Beim Training dieser KI-Modelle führt dies zu einer Verbesserung beider Netze.

Außerdem wurde auch im AP4 eine Prädiktion der zukünftigen Bewegung von Fahrzeugen in Zusammenarbeit mit AP3 entwickelt. Diese KI-basierte Fahrzeugprädiktion wurde im Rahmen des Prediction-Monitors eingesetzt, um die Abweichung zwischen vorhergesagter und tatsächlich gemessener Bewegung anderer Verkehrsteilnehmer zu messen und zu bewerten.

Für alle diese Metriken wurde daraufhin in den vorhandenen Versuchsträgern ein Aufzeichnungssystem in Betrieb genommen, mit dessen Hilfe automatisiert kritische Fahrsituationen erkannt und in diesen eine Datenaufzeichnung ausgelöst werden kann. Im Fahrbetrieb wurden sowohl die Metriken als auch das Aufzeichnungssystem getestet und validiert.

Im Rahmen des AP4 wurde insbesondere das Softwaremodul „Suspicious Driving Monitor“ entwickelt. Dieses KI-basierte Softwaremodul basiert auf einer Encoder/Decoder-Struktur, mit der die gemessenen Trajektoriendaten der erkannten Objekte, die Trajektorie des eigenen Fahrzeugs und die bekannte Karte der Umgebung verarbeitet werden. Die Eingangsdaten werden dabei mittels eines neuronalen Netzes in einen sog. Latenten Zustandsraum transformiert (Encoding), sowie der so erzeugte latente Zustandsvektor von einem weiteren neuronalen Netz in den realen Raum zurücktransformiert (Decoding). Über die Güte dieses Encoding-Decoding-Ergebnisses lässt sich zurückschließen, ob die

vorgefundene Verkehrssituation so oder so ähnlich bereits in den Trainingsdaten vorgelegen hat und somit einer normalen, unkritischen Situation entspricht, oder völlig unbekannt und damit potenziell kritisch ist. Auch über die Verteilung der Repräsentationsvektoren im latenten Raum lassen sich Rückschlüsse über die Art der Situation ziehen. Die beschriebene Architektur ist in Abbildung 3 dargestellt.

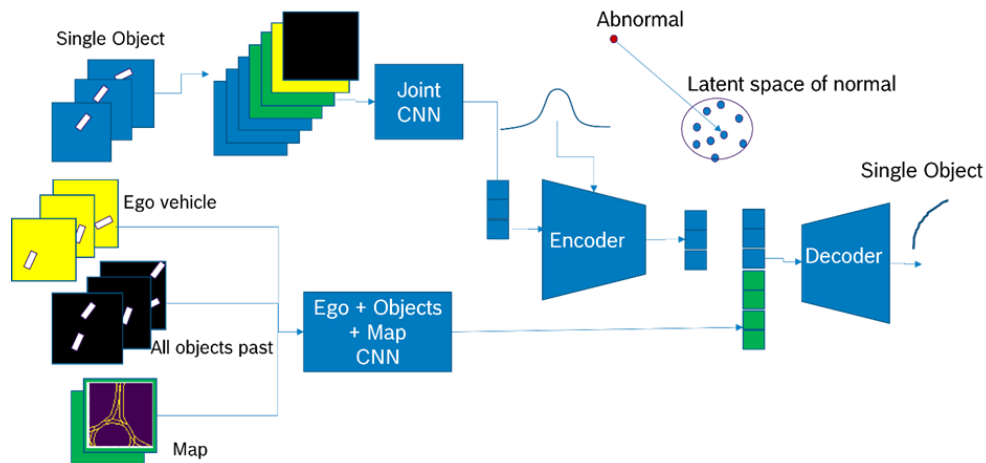


Abbildung 3: Architektur des SDM in Form eines Conditional Variational Autoencoders (CVAE).

Mit der Erkennung kritischer oder in diesem Kontext verdächtiger Verkehrssituationen ist lediglich der Sensierungsschritt durchgeführt worden. Das so erhaltene numerische Wissen über die Situation kann jedoch auch verwendet werden, um die Trajektorienplanung des Fahrzeugcontrollers anzupassen. Hier sind verschiedene Möglichkeiten denkbar, angefangen von einer einfachen Reduktion der maximal zulässigen Geschwindigkeit, bis hin zu örtlich-zeitlich aufgelösten Anpassungen der Kostenfunktion für die Trajektorienplanung oder als Verwendung für fortschrittliche Berechnung der räumlich-zeitlichen Gesamtkritikalität beispielsweise mithilfe von Subjective Logic Opinions (siehe Abbildung 4).




Abbildung 4: Verschiedene Ausbaustufen der Kritikalitätsmetriken. Von links nach rechts: Eingriff über Reduktion der maximalen Geschwindigkeit, Eingriff über gezielte örtliche und zeitliche Kritikalitätsrepräsentation, Verwenden von Subjective Logic Opinions zur Beschreibung der Gesamtkritikalität.

### Arbeiten zum Teilvorhaben

LiangDao war in AP4 nicht direkt vertreten. Allerdings erfolgte ein Austausch zu Arbeiten, die in mehreren APs verortet waren über gesonderte Meetings, etwa zu Metriken für die Beschreibung relevanter und kritischer Szenarien, welche u.a. in AP1, AP2, AP4 und AP5 behandelt wurden. Hier war LiangDao beteiligt.

### 2.1.5 AP5 – Szenarienerkennung

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

In TAP 5.1 - „Aufbau Testfahrzeug mit hochpräzisen Multisensor-System für Messfahrten“ haben verschiedene Partner unter Berücksichtigung der Ergebnisse von AP2 Konzepte für Datenaufnahme und -verarbeitung in Testfahrzeugen entwickelt und umgesetzt, bzw. bereits bestehende Systeme angepasst. Dazu wurden Testfahrten unternommen, um die jeweiligen Lösungen zu validieren und im weiteren Verlauf des Projektes zu optimieren.

Teil des Testfahrzeugaufbaus war außerdem TAP 5.2 - „Aufbau eines „Petabyte“-Level Datenbanksystems, Data Acquisition und Management“ in dem Lösungen zur Speicherung, Übertragung und Verwaltung der anfallenden Messdaten untersucht und dann adaptiert wurden. Mit dem Abschluss der TAPs 5.1 und 5.2 konnte Meilenstein M5.1 – „Aufbau Sensorsystem und Datenbanksystems für Datenakquise und -verwaltung“ erfüllt werden.

Neben dem Aufbau der Testfahrzeuge war die Entwicklung von KI-basierten Algorithmen für Echtzeit-Objekt- und -Szenarienerkennung eine Kernaufgabe des Arbeitspaketes und wurde in TAP 5.3 - „Entwicklung von echtzeitfähigen KI-Algorithmen für LiDAR Processing und Corner-Case-Szenarien Identifikation und Daten-Extrahierung (durch AP4 für ASAM OpenX konforme kompakte Beschreibung)“ bearbeitet. Dazu wurden die jeweiligen Anforderungen untersucht, Konzepte erstellt und Algorithmen entwickelt bzw. adaptiert. Die Ergebnisse aus AP3 für eine Adaptierung bereits existierender Algorithmen wurden berücksichtigt. Für die Objekt-Detektion wurden sowohl Algorithmen für die Verarbeitung von LiDAR- als auch Kamera-Daten entwickelt und eine bestehende Sensordatenfusion angepasst. Zusätzlich wurde eine Risikobewertung für Realdaten erstellt. Basierend auf diesen wurden relevante Szenarien simulativ nachgestellt und die Bewertungsmatrix aus TAP 1.1 überprüft.

Nach der prototypischen Umsetzung der Algorithmen folgte eine Phase der Integration, Optimierung und Validierung. Die Arbeiten geschahen im Rahmen von TAP5.4 - „Validierung und Optimierung des Risikomodells (mit AP1), der Szenarienerkennung mit HAD/AD Sensorik (mit AP 4) sowie Konzeption von Software-Werkzeugen (mit AP3 und AP7)“. Für Optimierung und Validierung wurden von verschiedenen Partnern Testfahrten durchgeführt; selbstständig, sowie im Verbund (siehe AP6). Auf diesen wurden Datensätze gesammelt, um die KI-basierten Algorithmen zu trainieren. Gleichzeitig wurden Datensätze gelabelt, um mit diesen die Ergebnisse der Verarbeitung zu validieren. Mit dem Einfahren der Datensätze wurde Meilenstein M5.2 - „Aufbau von KI-Trainingsdatensätzen durch reale Testfahrten“ erfüllt. Mit dem Testen und Validieren der KI-basierten Algorithmen konnte außerdem Meilenstein M5.3 - „Entwicklung, Test und Validierung von KI-Algorithmen für Szenarienerkennung“ abgeschlossen werden.

Im Rahmen von TAP 5.4 wurden außerdem Software-Werkzeuge für die Datenverarbeitung in der KIsSME-Pipeline erarbeitet. Einerseits, um die Risikomodellierung (AP1) und Datenselektion (AP4) zu integrieren, andererseits um die Echtzeitweitergabe der Daten an das Tool zur Generierung von ASAM konformen Szenariendaten für Simulationen (AP7) zu ermöglichen. Die verschiedenen Werkzeuge wurden jeweils in verschiedene Versuchsfahrzeuge integriert und getestet.

Für die Weitergabe an das Tool zur Generierung von ASAM konformen Szenariendaten (AP7) wurden in TAP 5.5 - „OpenX/ ASAM konforme bzw. erweiterte abstrakte Beschreibung der Szenarien“ Spezifikationen für die Beschreibung von Objekt- und Szenariendaten erarbeitet, Algorithmen zur Konvertierung erstellt, sowie Prozeduren zur Datenaggregation entwickelt und jeweils implementiert.

Gegen Ende der Projektlaufzeit erfolgte die Integration der letzten entwickelten Systeme in verschiedene Testfahrzeuge. Im Zuge dessen wurde Meilenstein M5.4 – „Integration KI-Szenarienerkennung im On-Board-System und Demonstratoren“ erreicht.

## Arbeiten zum Teilvorhaben

AP5 bildet den Kern des Teilvorhabens „Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien. Folgende Arbeiten wurden geleistet.

### 2.1.5.1 Aufbau Testfahrzeug mit hochpräzisen Multi-Sensorsystem für Vermessungsfahrten

Im Rahmen von KIsSME hat LiangDao einen eigenen Versuchswagen aufgebaut, mit dem einerseits die benötigten Trainingsdaten für das Antrainieren der KI-basierten Algorithmen aufgenommen, aber auch ein Großteil der entwickelten KIsSME-Pipeline getestet und validiert werden konnte.

Für den Aufbau wurden verschiedene Komponenten evaluiert und teils auch getestet. Das Schema ist in Abbildung 5 zu sehen.




Abbildung 5 Schema des finalen Versuchswagenbaus für KIsSME.

Als Plattform dient ein VW Passat Kombi. Die LiangDao Objekterkennung beruht auf LiDAR-Daten. Für das optimale Ergebnis im KIsSME-Kontext wurden verschiedene LiDAR-Sensoren evaluiert und getestet, auch an verschiedenen Positionen, z.B. 360°-LiDAR auf dem Dach und ein ausgerichteter LiDAR an der Frontseite des Fahrzeugs. Der Front-LiDAR wurde letztendlich für die Echtzeit-Messungen in der KIsSME-Pipeline ausgewählt. Außerdem sind unterstützend zwei RGB-Kameras mit Blick nach vorne verbaut. Der Videostream dient als zusätzliche Informationsquelle zum Labeln von Trainingsdaten bzw. wird als Referenz für Test und Validierung der LiDAR-Objekterkennung genutzt. Für die eigentliche Objekterkennung werden die Daten nicht verwendet. Fahrzeugdaten des Ego-Fahrzeugs (Geschwindigkeit, etc.) werden über eine CAN-Schnittstelle abgegriffen. Positiondaten über ein GPS/RTK-System erfasst. Ein Power-Management-System mit mehreren Batterien versorgt das gesamte System (Sensoren und Verarbeitung) mit der benötigten Energie.

Alle vier Datentypen werden über einen Switch sowohl direkt zum Datenlogger geführt, für das Speichern von Rohdaten (z.B. in der Trainingsphase), als auch zu einer OnBoard-Computing-Unit (OCU), welche die Rohdaten verarbeitet und erst eine Objekt- und

schließlich eine Szenarienerkennung durchführt. Der resultierende Datenstrom wird wieder an den Datenlogger weitergeleitet. Verarbeitete Daten können durch Installation eines 4G/5G Dongles auch während der Fahrt an ein Zieldatenzentrum transferiert werden. Die Übertragung wurde zum LiangDao Datenzentrum getestet. Eine Übertragung per 4G/5G wurde auch genutzt, um verarbeitete Daten aus dem Wagen direkt an einen Partner-Server für die Weiterverarbeitung in OpenX-konforme Szenarien-Daten zu übertragen, siehe AP7.

Falls bei einer Fahrt eine selektive Datenspeicherung gewünscht wird, kann diese manuell über einen Knopfdruck ausgelöst werden oder über die Szenarien-Detektion (am Ende des Projektes). Durch einen Zwischenspeicher, der die letzten Sekunden des Datenstroms speichert wird sichergestellt, dass als relevant eingeschätzte Szenarien komplett aufgenommen werden können, d.h. ohne Datenverlust am Beginn des Szenarios.

Der grundsätzliche Aufbau des Versuchswagens erfolgte in der ersten Hälfte des KISME-Projekts, dazu gehörten auch Testfahrten, um die Funktionalität der Subsysteme zu überprüfen. Anschließend erfolgte die schrittweise und vor allem softwarelastige Integration der Objekt- und Szenarienerkennung, inklusive der benötigten Fahrten zur Datensammlung, zum Test und zur Validierung der Systeme.

Um die Übertragbarkeit auf andere Anwendungsbereiche zu testen, z.B. Verwendung der Objekterkennung zur Verkehrsüberwachung mithilfe von Road Side Units (RSUs), wurde eine mobile RSU als Versuchsträger gebaut, siehe Abbildung 6, und die Algorithmen getestet. Dabei ergab sich eine prinzipielle Übertragbarkeit, welche nach Projektende angegangen werden soll, siehe 2.4 - Voraussichtlicher Nutzen.



Abbildung 6 Versuchsträger mobile RSU in verschiedenen Auslegungen, um die Übertragbarkeit der entwickelten Algorithmen für andere Anwendungsbereiche zu testen.

### 2.1.5.2 Aufbau eines „Petabyte“-Level Datenbanksystems, Data Acquisition und Management

Für das Speichern der umfangreichen Trainingsdaten, sowie für das eigentliche Training der KI-Algorithmen hat LiangDao am Entwicklungszentrum in Berlin eine umfangreiche Serverinfrastruktur aufgebaut, siehe Abbildung 7. Das Datenzentrum besteht aus einem Monitoring-Server, ein KI-Server, skalierbaren Labeling-Serverknoten und skalierbaren Speicherknoten. Die vom Fahrzeug gesammelten Daten können im Nachgang der Fahrten manuell an das Datenbanksystem übertragen werden, durch Ausbau der Festplatte und Übergabe an die Kopierstation oder über eine Wifi/LAN Verbindung. Auch eine Übertragung während der Fahrt über 4G/5G Lösungen ist möglich, allerdings für Rohdaten unpraktikabel. Alle vier Verbindungswege wurden mit verschiedenen Komponenten getestet und erfolgreich etabliert. Für eine schnelle Datenübertragung zwischen den Servern wurde ein Hochgeschwindigkeitsnetzwerk (10Gb/s) eingerichtet. Die erfassten Daten werden auf die Speicherknoten hochgeladen und abgespeichert. Auf dem KI-Server werden Trainingsdaten durch die Objekt- und Szenarienerkennung geleitet. Labeling-Aufgaben werden auf den Labeling-Serverknoten durchgeführt. Zur Überwachung aller Prozesse ist ein Monitoring-Server im Einsatz.

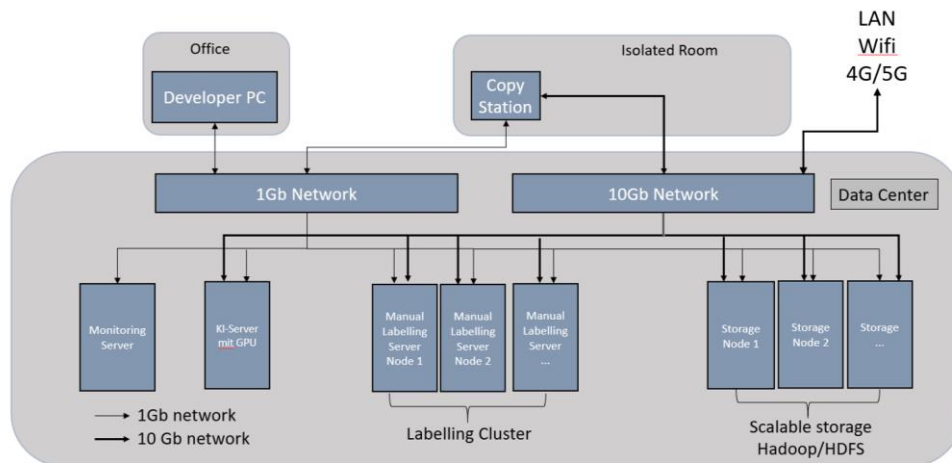


Abbildung 7 Schema LiangDao Datenzentrum.

### 2.1.5.3 Entwicklung von echtzeitfähigen KI-Algorithmen für LiDAR Processing und Corner-Case-Szenarien Identifikation und Daten-Extrahierung

Im Rahmen von KisSME hat LiangDao echtzeitfähige KI-basierte Algorithmen für Objekt- und Szenarienerkennung entwickelt. Die Objekterkennung folgt dabei dem Schema in Abbildung 8.

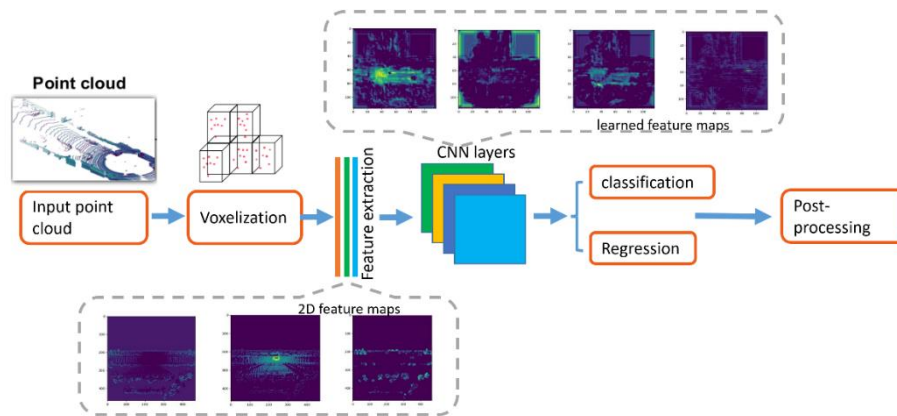


Abbildung 8 Grundsätzliches Schema des neuronalen Netzwerkes für Objekterkennung. LiDAR-Point Cloud stammt aus [21].

Dabei wird die LiDAR-Point Cloud vorverarbeitet durch ein neuronales Netzwerk geführt, Features werden klassifiziert und nachbearbeitet. Zentraler Bestandteil der Verarbeitungskette ist die sogenannte Semantic Segmentation, bei der die 3D Punkte einer Kategorie zugeordnet werden. Kategorien sind im Rahmen von KisSME verschiedene Fahrzeugklassen: PKW, LKW, Transporter, Fahrradfahrer und Fußgänger. Die Objekte werden mit erkannten Eigenschaften annotiert, wie etwa Größe, Ausrichtung, Geschwindigkeit oder Trajektorie (über mehrere Frames hinweg). Für eine Live-Verarbeitung während der Fahrten mit der in Echtzeit bzw. echtzeitnah eine automatisierte Datenselektion durchgeführt werden kann, ist es vor allem nötig ein Point-Cloud-Frame zu verarbeiten bevor das nächste die Verarbeitungskette erreicht. Der eingesetzte LiDAR produziert ein Frame alle 100ms. Im Gegensatz zu den regelbasierten Algorithmen, die LiangDao zuvor eingesetzt hat, war das Erreichen dieses Ziels mit dem KI-basierten Algorithmus schneller, in einer besseren Qualität und für mehr Klassen möglich. Ein entscheidender Faktor für die Optimierung ist das Antrainieren des neuronalen Netzwerkes mit ausreichend Trainingsdaten, siehe dazu TAP 5.4.

Im Gegensatz zur Objekterkennung, kann die Szenarienerkennung beliebig komplex werden. Einfache Szenarien sind z.B. das Einscheren eines anderen PKWs auf die Fahrbahn des Ego-Fahrzeugs (Cut-In), oder das Ausscheren von der eigenen Fahrbahn auf eine andere (Cut-Out). Dazu kommen etwa (zu-nahe) Vorbeifahrten, scharfe Beschleunigungs- und Bremsmanöver, Überhol- und Abbiegevorgänge, oder Kreuzungen der Trajektorien aber auch viele mehr. Das Ego-Fahrzeug kann ebenso die genannten Manöver durchführen. Und sie können kombiniert auftreten und von verschiedenen Arten von Verkehrsteilnehmern ausgeführt werden. Für ein einfaches Cut-In Beispiel siehe, Abbildung 9.



Abbildung 9 Cut-In Szenario auf der Autobahn, gelbe Pfeile deuten die Trajektorie des einherkommenden Fahrzeuges im Video, wie auch im LiDAR-Bild an.

LiangDao hat einzelne Szenario-Typen katalogisiert und Beispiele aus den gesammelten Daten für das Training extrahiert, entscheidend hierbei ist, dass die Objekte und ihre Eigenschaften nicht nur pro Frame, sondern zeitabhängig über mehrere Frames hinweg erfasst werden. Ein einfaches Beispiel für eine zeitabhängige Erfassung ist in Abbildung 10 für das Ego-Fahrzeug zu sehen. Hier wurden verschiedene Abbiege- und Wendemanöver aufgezeichnet.

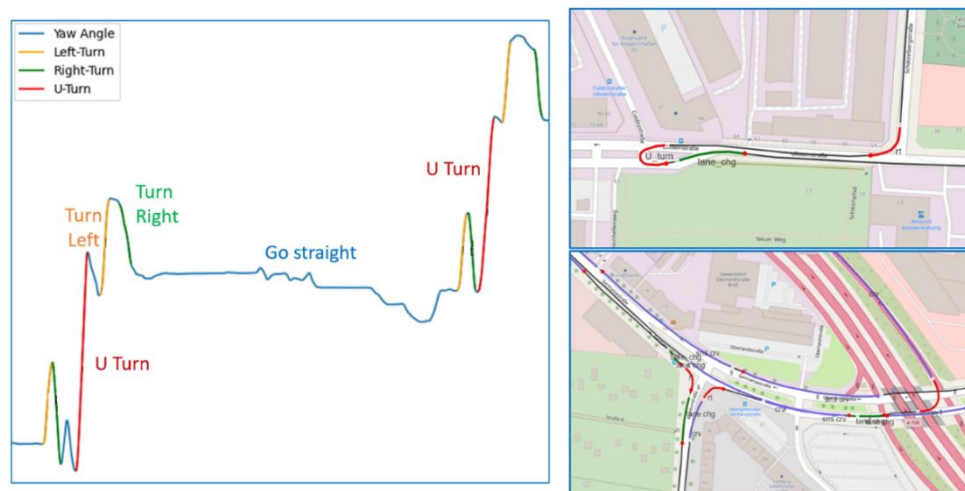


Abbildung 10 Beispiele für Abbiege- und Wendemanöver des Ego-Fahrzeugs. Links: zeitabhängig aufgetragen, rechts: visualisiert auf Karten.

Die Szenarienerkennung basiert auf über 1000 Parametern, aufgeteilt auf verschiedene Kategorien, bei der auch der Fahrer (z.B. sein Fahrstil) und Umwelteinflüsse berücksichtigt werden. Die gegebenen Daten werden auf die definierten Parameter hin analysiert, extrahiert weiterverfolgt und für die Szenarienerkennung herangezogen. Dazu gehören prototypisch

auch Kritikalitätsmetriken die in AP1 erarbeitet und gesammelt wurden (z.B. time-to-collision). siehe Abbildung 11. Eine Optimierung der Szenarienerkennung erfolgte auch hier in Rahmen TAP5.4 mit weiteren Testfahrten. Die entwickelte Beschreibung von Objekten und Szenarien erfolgte im Einklang mit ASAM OpenX-Standards.

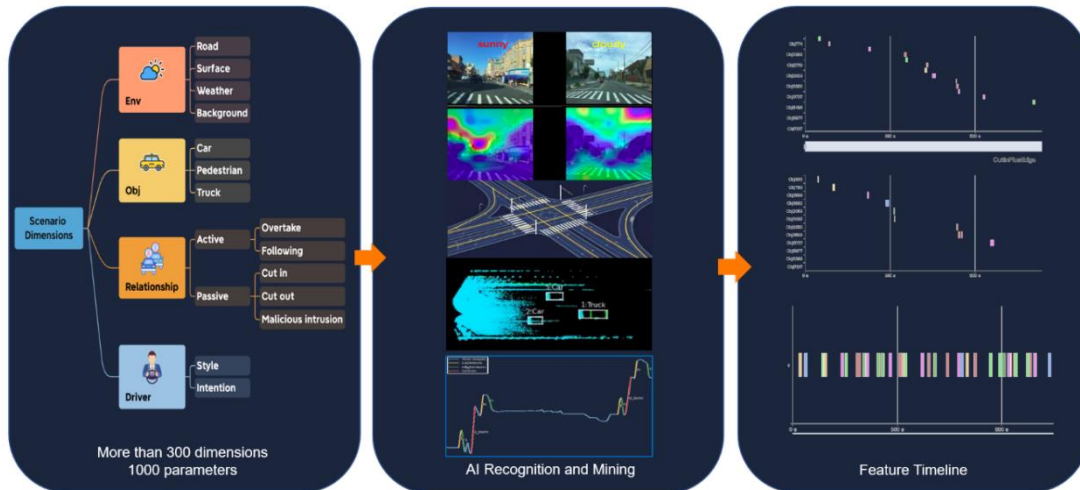


Abbildung 11 Konzept der automatischen Szenarienerkennung.

#### 2.1.5.4 Validierung und Optimierung des Risikomodells der Szenarienerkennung mit HAD/AD Sensorik, sowie Konzeption von Softwarewerkzeugen

Ein großer Teil des TAPs waren LiangDao eigene Fahrten mit dem Versuchsfahrzeug, welche der weiteren Sammlung von Testdaten für die Optimierung der KI-basierten Algorithmen dienen, wie auch zum Testen und Validieren ihrer Performance. Hierzu wurden Fahrten in verschiedenen Regionen und Umgebungen durchgeführt siehe Abbildung 12.




Abbildung 12 Übersicht der Regionen in denen Fahrten für Training, Test und Validierung der KI-basierten Algorithmen durchgeführt wurden. Daten wurden in Städten, im ländlichen Raum und auf Autobahnen aufgezeichnet.

Für Test und Validierung wurden die Algorithmen in das OnBoard-System integriert und damit der OnBoard-Teil der KIsSME Pipeline geschlossen.

#### 2.1.5.5 OpenX/ASAM konforme bzw. erweiterte abstrakte Beschreibung der Szenarien

Für die Weitergabe an den OffBoard-Teil der KIsSME-Pipeline war eine Abstimmung über die nötigen Dateiformate nötig, in Übereinstimmung mit ASAM OpenX-Standards aber auch darüber hinaus. Dazu erfolgte ein regelmäßiger Austausch, vor allem mit Partner MindMotiv, inklusive eines Tests der vollständigen Pipeline. Die Arbeiten überlappten sich mit jenen in AP7, siehe 2.1.7- AP7 – Szenariengenerierung.

### 2.1.6 AP6 – Datenakquisition

Das Arbeitspaket 6 befasste sich mit der selektiven Datenakquisition im realen Umfeld sowie in Testumgebungen. Hierunter fiel auch die Koordination verschiedener Versuchsfahrten der Projektpartner sowie die Validierung der im Projekt entwickelten Algorithmen. Das Arbeitspaket 6 gliederte sich in vier Teilarbeitspakete.

In TAP6.1 „Erstellung von Szenarien zur automatischen Bewertung der Testfahrten (AP5.1) bzw. der automatischen Generierung von standardkonformer Beschreibung von Szenarien (AP7)“ wurden erste Szenarien für die Versuchsfahrten ausgearbeitet und in einem Drehbuch zusammengefasst. Beispiele sind Überholmanöver oder Abbiegeszenarien. Voraussetzung für die Szenarien war, dass ein möglichst großer Realitätsbezug vorhanden war und eine ausreichende Kritikalität für AD-Fahrfunktionen bestand. Hierfür wurden die jeweiligen Metriken aus AP1 berücksichtigt (bspw. Beschleunigung, kreuzende Fahrwege etc.). Somit war eine Evaluierung der Bewertungsverfahren aus AP1 bzw. die in KisSME entwickelten Algorithmen möglich. Das Drehbuch wurde im Laufe des Projektes erweitert und diente jeweils als Grundlage für die Versuchsfahrten in TAP6.2.

Die erstellten Szenarien wurde erstmalig bei einem Versuchstag im Dezember 2021 auf dem Campus Ost des KIT erprobt. Insgesamt wurden vier Versuchstage durchgeführt, welche Bestandteil des TAP6.2 „Durchführung von Testfahrten im öffentlichen, urbanen Verkehr (u.a. TAF-BW) mit verschiedenen Testfahrzeugen (Pkw, People-Mover, Transporter, Kommunalfahrzeug) und den jeweils relevanten HAD/AD-Funktionen“ waren. Zwei weitere Versuchstage erfolgten auf dem Campus Ost des KIT (im Mai 2022 und im Oktober 2022) sowie ein Versuchstag im Innenstadtbereich von Karlsruhe (April 2023). Die Projektpartner mit Versuchsfahrzeugen waren hierbei beteiligt, allerdings wirkten weitere Projektpartner (ohne Versuchsfahrzeug) als Statisten bzw. zur Aufnahme der Szenarien von außen mit. Dies erfolgte mithilfe von Kameras, einer Drohne sowie eines mobilen Sensorpfosten. Die Versuchsfahrzeuge erfassten mithilfe diverser Sensorik (Kamera, LiDAR, RADAR) die Fahrzeugumgebung. Eine Anpassung der Szenarien wurde für jeden Versuchstag vorgenommen wie bspw. die Verdeckung von Verkehrsteilnehmern oder Beteiligung von Fahrzeugen verschiedener Bauart (Lastenfahrrad, Pkw-Anhänger, Einsatzfahrzeug der Werkfeuerwehr des KIT). Für die Versuchsfahrten im Stadtbereich Karlsruhe wurden fünf verschiedene Standorte mit kritischen Verkehrsaufkommen gewählt (bspw. Oststadtkreisel). Auf dem Campus Ost des KIT war mit einer Forschungskreuzung mit Fahrstreifenmarkierungen und Lichtsignalanlage eine realitätsnahe Verkehrsinfrastruktur vorhanden. Zusätzlich wurden Verkehrsschilder aufgestellt, um bspw. Vorfahrtsverletzungen nachzustellen. Die Ampelanlage konnte weiterhin in beliebigen Programmschaltungen gesteuert werden, sodass auch eine Rotlichtfahrt nachgestellt wurde. Neben den Versuchsfahrzeugen wirkten auch die jeweiligen Projektpartner als Statisten mit (bspw. Passant überquert Straße, Fahrt mit Lastenfahrrad etc.). Eine Verdeckung wurde durch geparkte Fahrzeuge (u.a. auch mit einem Lkw) simuliert. Bei der Aufzeichnung der Daten war von Beginn das Thema Datenschutz im Fokus. Es wurden zwei Datenschutz-Workshops mit den Datenschutzabteilungen der Projektpartner durchgeführt und ein Datenschutzkonzept ausgearbeitet. Hierunter war eine Datenschutzerklärung, welche jeder Projektpartner bei der Teilnahme an den Versuchsfahrten am Campus Ost des KIT unterzeichnete. Weiterhin wurde am Campus Ost der Publikumsverkehr durch sogenannte Kundenstopper mit einem Datenschutzhinweisschild informiert bzw. vorgewarnt. Für die Versuchsfahrten im öffentlichen Verkehrsraum setzte zusätzlich jeder Projektpartner eine Datenschutzfolgenabschätzung auf, welche jeweils öffentlich verfügbar waren bzw. sind. Die Ablage und der Austausch der aufgezeichneten Daten erfolgten auf einem Server des KIT. Es fand eine Trennung der Laufwerke in Sachdaten und personenbezogene Daten statt. Hierdurch hatten jeweils nur berechnete Projektpartner einen Datenzugriff. Aus den aufgezeichneten Daten wurden Objektlisten erstellt, welche als Input zur Validierung der in

KIsSME entwickelten Algorithmen dienen, insbesondere der Kritikalitätsalgorithmen. Zusätzlich zu den oben genannten Versuchstagen, führten die Projektpartner eigenständig weitere Versuchsfahrten durch.

Zusätzlich zu den erhobenen Realdaten wurden virtuelle Szenarien erstellt. Dies war Bestandteil des TAP6.3 „Nutzung der Daten aus den Fahrversuchen für selektive Closed Vehicle-in-the-Loop Simulation im Teststand des KI zur Bewertung der Resultate, einschl. Parametervariationen zur Re-Simulation“. Aus den erstellten Szenarien wurden Objektlisten abgeleitet, welche wiederum wie in TAP6.2 als Input zur Validierung der Kritikalitätsalgorithmen dienen.

Abschließend wurden die aufgezeichneten Realdaten sowie die virtuellen Daten bzw. Objektlisten zur Validierung der in KIsSME entwickelten Algorithmen verwendet. Neben den Kritikalitätsalgorithmen waren dies bspw. die Streaming- oder OTX-Komponente. Das TAP6.4 „Nutzung der Daten aus den Fahrversuchen sowie der Test-Szenarien (AP6.1) am Vehicle-in-the-Loop Prüfstand zur Bewertung der automatischen Generierung von standardkonformer Beschreibung von Szenarien (AP7)“ war hierfür vorgesehen. In wöchentlichen Besprechungen mit allen Projektpartnern wurde das Vorgehen koordiniert. Der Fokus lag auf den notwendigen Parametern sowie dem Dateiformat der Objektlisten als Input für die Algorithmen. Praxistests in den On-Board-Systemen der Versuchsfahrzeuge (online) sowie mithilfe der Objektlisten aus den Real- und Simulationsdaten (offline) wurden geplant und erfolgreich durchgeführt.

### **Arbeiten zum Teilvorhaben**

LiangDao war in die Erstellung der Szenarien und der Planungen für die Durchführung der Versuchsfahrten vollumfänglich beteiligt (TAP6.1). Auch nahm LiangDao mit dem im Rahmen von KIsSME entwickelten Fahrzeug (siehe AP5) an jedem der gemeinsamen Versuchsfahrten in Karlsruhe teil (TAP6.2), siehe Abbildung 13 für ein Bild der teilnehmenden Partnerwagen am letzten Versuchstag im April 2023. Während der Fahrten wurden von jedem Versuchsfahrzeug insgesamt mehr als 100 Szenarien durchfahren, teils in unterschiedlichen Ausführungen. Die Fahrten mit geplanten Szenarien am Campus Ost des KIT fokussierten sich auf spezielle Szenarien an gewöhnlichen Straßenabschnitten, siehe etwa Abbildungen 14-16.

Die Fahrten im öffentlichen Raum fokussierten sich dagegen auf Fahrten durch ungewöhnliche Infrastruktur, siehe beispielhaft die Abbildungen 17-19. Bei den Fahrten im öffentlichen Raum ist bereits das finale System der Objekterkennung installiert. Abbildungen 17-19 zeigen daher in der oberen Hälfte das RGB-Video-Bild aus dem Fahrzeug (unterstützend) und in der unteren Bildhälfte die LiDAR-Punktwolke mit den über die Objekterkennung annotierten Fahrzeugen.

Die Rohdaten aller Versuchsfahrten wurden in Objektlisten weiterverarbeitet und den Partnern datenschutzkonform und kompatibel zu den partnerspezifischen Systemen zur Verfügung gestellt. Dies erfolgte nicht nur im Rahmen von TAP6.3 und TAP6.4 als Grundlage für die Arbeiten an den Vehicle-in-the-Loop Simulationen, sowie am Vehicle-in-the-Loop-Prüfstand, sondern allgemein, um etwa eine Realdatengrundlage für Entwicklung von Systemen zur Bewertung der Kritikalität bei den Partnern zu ermöglichen. Die aufgenommenen Daten wurden außerdem in der LiangDao eigenen Szenarien Datenbank abgespeichert und für das Training der KI-Algorithmen verwendet.



Abbildung 13 Wagen der teilnehmenden Partner der Versuchsfahrten im April 2023. Das Fahrzeug von LiangDao ist das 2. von rechts.



Abbildung 14 Szenario Überholen an einer Kreuzung.



Abbildung 15 Szenario mit Fahrt vorbei an einem Feuerwehrwagen im Einsatz.



Abbildung 16 Szenario mit Fahrrad und Anhänger.




Abbildung 17 Szenario im Wäldchen.



Abbildung 18 Szenario in einem mehrspurigen Kreislauf.

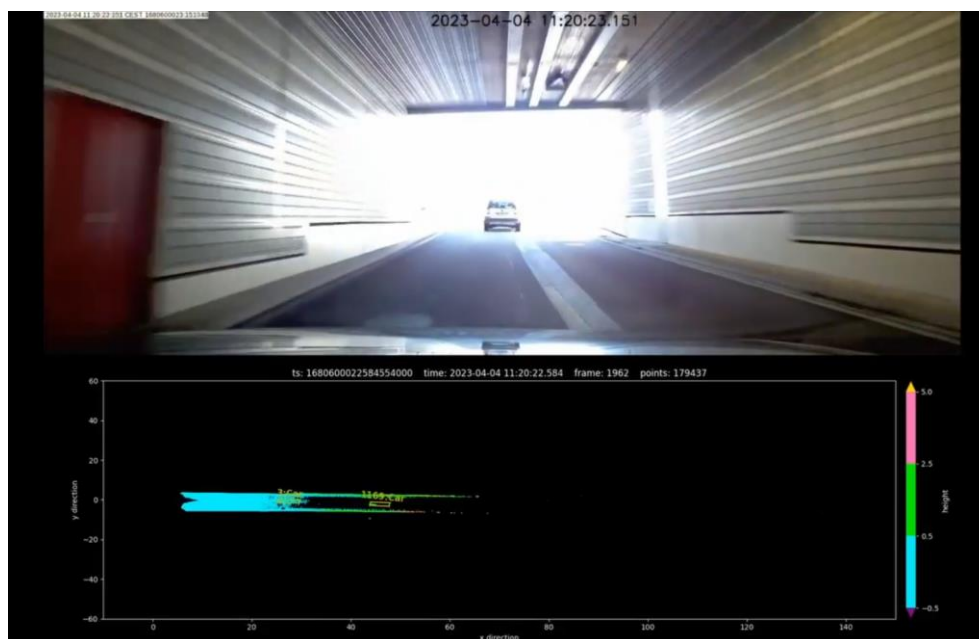


Abbildung 19 Szenario an einer Tunnelausfahrt.

### 2.1.7 AP7 – Szenariengenerierung

Das AP 7 befasst sich mit der Implementierung einer Cloud-Anwendung, deren Ziel der Empfang, die Konvertierung in standardkonforme Formate und die Persistierung sowie Aufbereitung und Nachverarbeitung von Daten, die eine Verkehrssituation darstellen, ist. Dazu werden Streaming-Protokolle zum Datenerhalt sowie die manuelle Bereitstellung von aufgezeichneten Daten unterstützt, Konfigurierbarkeit der zu streamenden Daten via Open Test Exchange-Standard (OTX) berücksichtigt, die Plausibilität der erzeugten Ergebnisse eingeschätzt und Methoden zur Generierung von Varianten der Szenarien untersucht.

Im Rahmen der Bearbeitung von TAP 7.1 - Anbindung an die in AP3 und AP5 entwickelten Echtzeitkomponenten im Fahrzeug, bspw. via LTE, wurde die Übertragung von Daten, die in Fahrzeugen in Echtzeit gemessen, aufgezeichnet und mit KI-basierten Algorithmen verarbeitet werden, über eine drahtlose Schnittstelle an ein Off-Board Cloud-System umgesetzt. Dazu wurden unter anderem Anforderungen an die Fahrzeugkomponenten, insbesondere im Kontext des AP3 und AP5, ausgearbeitet. Diese umfassen sowohl Anforderungen an die Umfelderkennung, um basierend auf den empfangenen Daten standardkonforme Szenarienbeschreibungen generieren zu können, als auch für die drahtlose Datenübertragung. Letztere wurde im Kontext von TAP 7.1 umgesetzt, indem geeignete Übertragungsprotokolle identifiziert, ausgewählt und die nötige Software- und Hardware serverseitig in Betrieb genommen wurden. Außerdem wurden entsprechende Gegenstücke im On-Board-System integriert und laufend angepasst.

Das Teilarbeitspaket TAP 7.2 - Zuordnungen der Szenariendaten zu den Eigenschaften der OpenX-Standards, Analyse von Überschneidungen und Abhängigkeiten, sowie von Validierungsoptionen (aufbauend auf AP 1.3 und AP 5.3) befasste sich mit drei Themen: Der Herleitung von Abbildungsvorschriften von erhobenen und verarbeiteten Daten auf ASAM OpenScenario und OpenDrive Standards, der Konzeption und Anforderungsspezifikation einer OTX-Komponente zur situationsbasierten Steuerung der Datenübertragung und Szenariengenerierung, sowie der Entwicklung KI-basierter Methoden zur Generierung weiterer Szenarien auf der Basis von GANs.

Aufbauend und ergänzend zu den Arbeiten aus TAP 7.1, sowie TAP 7.2 wurden im TAP - 7.3 Design und Implementierung eines Werkzeugs zur Validierung, Verfeinerung und Erzeugung von OpenX-Dateien aus den übermittelten Szenariodaten, insbesondere für bisher "unexampld" Szenarios (OpenX Erweiterungen) die Hauptkomponenten der Off-board-Cloud-Anwendung entworfen und realisiert. Mit dem Ziel hoher Verfügbarkeit, Flexibilität und Skalierbarkeit wurde eine Microservice-basierte Architektur mit REST und REST-ähnlichen Schnittstellen gewählt, bei der Komponenten redundant und dynamisch zu einem laufenden System hinzugefügt werden können. Die konzipierte und implementierte Cloudanwendung adressiert dabei Aspekte des Nutzer- und Datenmanagements, den parallelen Betrieb unterschiedlicher Fahrzeuge, die zeitgleich Daten streamen, die (konfigurierbare) Datenhaltung der Eingangsdaten und der generierten Szenarienbeschreibungen, eine Web-Benutzerschnittstelle zum Zugriff auf das System um Auslastung, verfügbare Ressourcen oder Ergebnisse grafisch darzustellen sowie Konfigurationen und Parametrierungen vorzunehmen. Mit Verfügbarkeit der ersten Versionen dieser Komponenten konnte schließlich der Meilenstein M 7.1 erreicht werden. Darüber hinaus wurde im Zuge des TAP 7.3 auch die Umsetzung des OTX-Runtime Konzept, wie in TAP 7.2 entworfen, realisiert werden.

Über die Projektlaufzeit wurden laufend Aktualisierungen der bereits erarbeiteten Ergebnisse vorgenommen, um dem sich laufend verändernden Technik- und Informationsstand gerecht zu werden. Diese wurden teilweise als Bestandteil der jeweiligen Arbeitspakete, aber insbesondere als Bestandteil von TAP 7.4 - Erarbeitung von Mechanismen zur Validierung und Verfeinerung der Methoden aus AP 7.2 und AP 7.3 mittels asynchron übertragener

Objekt- und Sensordaten vom Fahrzeug umgesetzt. Dieser Aspekt, der sich ständig erweiternden Informationslage spiegelt sich auch im als Teil von TAP 7.4 neu adressierten Anwendungsfall der asynchron übertragenen Objekt- und Sensordaten vom Fahrzeug wider. Dazu wurden einerseits Komponenten angepasst, um mit umfangreicheren Daten umgehen zu können und die Möglichkeit geschaffen aufgezeichnete Daten manuell in das Cloudsystem nachzuladen.

Die Bearbeitung des TAP 7.5 - Erarbeitung eines Verfahrens zur Bewertung der Konfidenz der Szenarienelemente anhand eines Punkteschemas befasste sich mit der Beurteilung von generierten Szenarien mit dem Ziel die Konfidenz der Ergebnisse bewerten zu können. Dabei wurde die wesentliche Herausforderung identifiziert, dass bei der Szenariengenerierung komplementäre, aber nicht redundante, Daten aus unterschiedlichen Quellen verwendet werden und keine „Ground Truth“ bekannt ist. Das erarbeitete Bewertungsschema gibt entsprechend Aufschluss darüber, ob das Resultat einer Szenariengenerierung eine mögliche Verkehrssituation darstellt oder nicht. Für den Fall einer nicht-möglichen Situation bedarf es einer manuellen Überprüfung der Umstände, ob die Generierung erfolgreich war, die Datenlage jedoch dazu führt das potenziell unplausible Ergebnisse generiert werden. Im Falle einer möglichen Fahrsituation kann jedoch keine Aussage darüber getroffen werden, ob das generierte Szenario tatsächlich den realen Sachverhalten entspricht oder nicht, beispielsweise durch fehlerhafte Kartendaten.

### **Arbeiten zum Teilvorhaben**

LiangDao war in dem von MindMotiv geleiteten Arbeitspaket in allen TAPs unterstützend tätig, durch Bereitstellung von Datensätzen mit Objekt-, Ego- und Szenariendaten, mit denen die Systeme von MindMotiv entwickelt und getestet werden konnten. Außerdem erfolgte ein ständiger Austausch, um die Kompatibilität der von LiangDao gelieferten Daten mit den Systemen des Partners, im Einklang zu OpenX-Standards und darüber hinaus.


Im August 2023 erfolgte bei einem bilateralen Treffen in Berlin ein abschließender Test zwischen den Systemen von LiangDao und jenen von MindMotiv. Bei einer Fahrt durch die Stadt wurden OnBoard und in Echtzeit aus den gewonnenen LiDAR Rohdaten Objektlisten erstellt. Diese wurde per 5G an die Server von MindMotiv in Aachen übertragen und dort weiterverarbeitet. Abbildung 20 zeigt das Team von LiangDao und MindMotiv vor der Testfahrt.



Abbildung 20 Team von LiangDao und MindMotiv vor der Testfahrt, bei der die Anbindung des LiangDao Versuchsfahrzeugs in Berlin an den MindMotiv-Server in Aachen via 5G erfolgte und in Echtzeit prozessierte Objektlisten übertragen werden konnten.

### 2.1.8 AP8 – Demonstratoren

In AP8 wurden die Ergebnisse des Projekts an realen Demonstratoren dargestellt. Dabei wurden einerseits die Demonstratoren zur Gewinnung von Testdaten als auch zur Validierung der in den anderen APs erarbeiteten KI-basierten Lösungen verwendet. Der Demonstrator von LiangDao wurde bereits in AP5 vorgestellt. Nachfolgend sind alle in KISME aufgebauten und eingesetzten Demonstratoren aufgeführt:

Name des Demonstrators	<b>PKW im urbanen Kreuzungsbereich</b>
Verantwortlicher Partner	FZI Forschungszentrum Informatik
Typ des Demonstrators	CoCar NextGen: PKW auf Basis eines Audi A6 Avant CoCar: SUV auf Basis eines Audi Q5
Einsatzort des Demonstrators	Reales Testfeld öffentlich: Urbaner Kreuzungsbereich
Beschreibung des Demonstrators	<p>CoCar ist ein automatisiertes Fahrzeug auf Basis eines Audi Q5. Es besitzt umfangreiche Sensorik, wie Kamera und LiDAR-Sensoren, um seine Umwelt korrekt wahrnehmen zu können. Dadurch ist es befähigt automatisiert am Straßenverkehr teilzunehmen. Da das selektive Datenlogging im Vordergrund steht, soll CoCar in diesem Projekt als Mess- und Erprobungsfahrzeug für open-loop Komponenten hochautomatisierter Fahrfunktionen genutzt werden. Der Nachfolger CoCar NextGen besitzt ein deutlich umfangreicheres Sensorsetup, bestehend aus 12 LiDAR-, 9 Kamera- und 2 Radarsensoren. CoCar NextGen kann automatisiert fahren, wurde in diesem Projekt aber ausschließlich zur Sammlung von Daten genutzt.</p> <div style="display: flex; justify-content: space-around; align-items: center;">   </div>
Beschreibung der durchgeführten Versuche	Im Rahmen des Projekts KISME wurden die Versuchsträger eingesetzt, um die entwickelten Algorithmen im Use-Case urbane Kreuzung hinsichtlich des effizienten Datenlogging zu erproben. Kreuzungen bieten durch die erhöhte Anzahl an verschiedenartigen Verkehrsteilnehmern eine ideale Testumgebung. des Szenarios.
Bezug zu den Arbeitszielen	CoCar wurde eingesetzt, um die entwickelten Systemarchitekturen (AP2) und Prädiktionsverfahren (AP3) an realen Szenarien zu


	erproben und zu verifizieren. CoCar NextGen stand erst gegen Ende der Projektlaufzeit zur Verfügung und wurde für die Datenakquise genutzt. Der Einsatz und Test der KI-Verfahren im realen Verkehr sind neben den Simulationsverfahren integrale Bestandteile des im Projekt durchgeführten Technologiehubs.
Metriken zur Bewertung der Demonstration	<ul style="list-style-type: none"> <li>• Güte der Szenarienprädiktion in urbanen Bereichen mit einer erhöhten Anzahl an nichtmotorisierten Verkehrsteilnehmern (Abweichung zur Ground Truth)</li> <li>• Technologiereife des OnBoard Systems, bestehend aus Trigger und Logger.</li> </ul>

Name des Demonstrators	<b>People-Mover im öffentlichen Raum</b>
Verantwortlicher Partner	Robert Bosch GmbH
Type des Demonstrators	Reales Fahrzeug als People-Mover
Einsatzort des Demonstrators	Reales Testfeld nicht öffentlich
Beschreibung des Demonstrators	<p>Eine besondere Herausforderung stellt dabei die Sicherheit dar, die durch entsprechende Redundanzen, Rückfallebenen und Überwachungen gewährleistet werden soll. Die Entwicklung dieser Sicherheitsmerkmale stellt den Schwerpunkt bei der Erprobung mit dem Shuttle dar.</p> <p>Besondere Forschungsthemen sind:</p> <ul style="list-style-type: none"> <li>• Technische Überwachung zur Gewährleistung der Sicherheit im Betrieb sowohl im Regel- wie auch im Fehlerfall</li> <li>• Systematische Abdeckung aller relevanten Szenarien</li> <li>• Kontinuierliche Überwachung im Feldversuch, systematische Verbesserung anhand von erfassten Szenarien.</li> </ul> <p>Das Fahrzeug ist aufgebaut als Versuchsträger auf der Plattform EZ10 der Firma Easymile und mit Sensorik und AD-Technologie der Bosch Forschung erweitert worden.</p>



Bosch Demonstrator bei der Abschlussveranstaltung am 28.11.2023 in Renningen mit einem Teil des Bosch-Teams und dem Konsortialleiter.

Das KIsSME-Triggerframework wurde im zentralen Display im laufenden Betrieb in Echtzeit visualisiert.



Darstellung der online im zentralen Display des Versuchsträgers dargestellten Kritikalitäten, hier TTC und Distanz. Die Situation zeigt keine TTC, da sich kein Objekt auf Kollisionskurs befindet. Die geringste Distanz zu einem Objekt liegt im dargestellten Zeitschritt bei ca. 7 m.

Beschreibung der durchgeführten Versuche


Im Rahmen des Projekts KIsSME wurde der Versuchsträger eingesetzt, um die erforschten und vorentwickelten Verfahren und Ansätze der verbesserten Umfeldinterpretation sowie zum selektiven Datenlogging für autonome Fahrzeuge zu erproben. Die Fahrstrecken und Fahrzeit wurden so umfänglich gewählt, dass notwendige Erkenntnisse möglich waren und z.B. auch nur gelegentlich zu loggende Ereignisse aufgezeichnet werden können. Das Fahrzeug wurde im Testbetrieb automatisiert betrieben. Es war kein Regelbetrieb vorgesehen.

Aufgrund einer erst in den letzten Monaten des KIsSME Projekts erfolgte Straßenzulassung wurden alle Messfahrten auf nicht-öffentlichen Straßen durchgeführt. Für die notwendige Messfahrten auf öffentlichen Straßen wurden weitere Versuchsträger der Robert Bosch GmbH mit geeigneter Sensorik und Datenspeichermöglichkeiten verwendet.

Bezug zu den Arbeitszielen	Der People Mover wurde eingesetzt, um die entwickelten Systemarchitekturen (AP2), Prädiktionsverfahren (AP3) und Metriken (AP1, AP3, AP4) im Realbetrieb an realen Szenarien zu erproben und zu verifizieren. Die Datenakquise aus realen Szenarien und mit realen Messdaten sowie der Einsatz und Test der KI-Verfahren im realen Verkehr sind neben den Simulationsverfahren integrale Bestandteile des im Projekt geplanten Technologiehubs.
Metriken zur Bewertung der Demonstration	<ul style="list-style-type: none"> <li>• Güte der Umfeldprädiktion in realistischen Szenarien (Abweichung Prädiktion – Ground Truth)</li> <li>• Effizienz der Datenspeicherung</li> <li>• Technologiereife / Einsetzbarkeit des Loggingframeworks im Entwicklungsprozess (Erweiterbarkeit um weitere Selektoren)</li> </ul>

Name des Demonstrators	<b>Transporter in verkehrsberuhigten Zonen und Übergangszonen</b>
Verantwortlicher Partner	Karlsruher Institut für Technologie (KIT)
Typ des Demonstrators	Reales Fahrzeug auf Basis eines Mercedes-Benz Sprinter Tourer
Einsatzort des Demonstrators	Das Versuchsfahrzeug wurde einerseits auf dem Campus Ost des KIT (öffentlicher, aber durch Schranken getrennter, nicht frei zugänglicher Bereich) eingesetzt. Hier ermöglicht eine Erprobungskreuzung mit einer Lichtsignalanlage die Darstellung nahezu beliebiger Fahrsituationen, so dass gemeinsam mit den Fahrzeugen der anderen Projektpartner kritische Szenarien durchfahren werden konnten. Weiterhin erfolgte ein Einsatz des Fahrzeuges bei weiteren Testfahrten im Stadtgebiet von Karlsruhe.
Beschreibung des Demonstrators	<p>Beim Demonstrator handelt es sich um ein Mess- und Erprobungsfahrzeug auf Basis Mercedes-Benz Sprinter Tourer 316 CDI. Das Fahrzeug wurde zu Beginn des Projektes entsprechend der verschiedenen projektspezifischen Anforderungen angepasst. Unter anderem stehen diverse Sensorik, darunter sechs LIDAR, zwei Kameras, eine Positioniereinheit inkl. Kamera und ein GNSS-Receiver inkl. Inertialer Messeinheit (IMU) zur Verfügung. Weiterhin ist das Fahrzeug mit einem Serverschrank inkl. Hochleistungs-PC zur Datenaufzeichnung und -Verarbeitung, einem Geräteregal mit integrierter Energieversorgung (Batterien, Wechselrichter, Ladegerät etc.) sowie zwei mobilen Arbeitsplätzen (vier Bildschirme, zwei Sitze) ausgerüstet.</p> <p>Für die Datenaufzeichnung wurde eine Datenschutzfolgenabschätzung durchgeführt. Für die Erfassung von Kamerarohdaten ist ein Anonymisierungsalgorithmus vorhanden, der automatisiert während der Aufzeichnung bspw. Gesichter von Passanten erkennt und verpixelt. Es werden somit nur datenschutzkonforme Daten auf dem Fahrzeugserver gespeichert. Das Fahrzeug besitzt vier Nivellierstützen, um bspw. bei Aufnahmen im Stillstand eine möglichst</p>

exakte Aufzeichnung zu garantieren. Softwareseitig wurde mit Ubuntu 20.04 gearbeitet, für die Datenaufzeichnung nutzt das Fahrzeug das Robot Operating System (ROS1) sowie die Programmiersprachen Python und C++. Für die manuelle Datenaufzeichnung und Darstellung der von der Sensorik erfassten Umgebung wurde eine GUI entwickelt. Hierbei ist es per drag and drop möglich, Daten automatisiert aufzuzeichnen bzw. auch zu extrahieren.



Beschreibung der durchgeführten Versuche

Im Rahmen des Projekts KisSME wurde das Fahrzeug für Fahrten eingesetzt, mit deren Hilfe Realdaten für die im Projekt entwickelten Algorithmen (metrikbasierte und KI-basierte Kritikalitätsalgorithmen, Streaming-Komponente etc.) für die Projektpartner erfasst wurden. Weiterhin wurde auch eine online Validierung im Fahrzeug für einen Teil der Algorithmen durchgeführt. Für die Datenaufzeichnung stand einerseits der Campus Ost des KIT zur Verfügung. Dabei handelt es sich um einen öffentlichen Verkehrsraum, welcher über ein Straßennetz und eine Ampelkreuzung verfügt und zusätzlich durch Schranken zum öffentlichen Verkehrsnetz abgetrennt ist. Hierbei war es möglich, diverse kritische Szenarien mit den anderen Versuchsfahrzeugen ohne Eingriff in das öffentliche

	Verkehrsgeschehen durchzuführen. Die kritischen Szenarien enthielten unter anderem: Verdeckung von Passanten, Fahrradfahrern und Pkws, Vorfahrtsverletzungen, Überholmanöver oder auch die Beachtung von Einsatzfahrzeugen der Feuerwehr. Neben diesen Tests wurde auch eine Versuchsfahrt mit den Projektpartnern im Stadtgebiet Karlsruhe durchgeführt. Hierunter waren ein Kreiselszenario, eine Tunneldurchfahrt, Abbiegen unter Beachtung eines Fahrradweges sowie vielbefahrene Kreuzungen.
Bezug zu den Arbeitszielen	Das Messfahrzeug wurde eingesetzt, um die entwickelten Systemarchitekturen (AP2), Prädiktionsverfahren (AP3) und Metriken (AP1, AP3, AP4) an realen Szenarien zu erproben und zu verifizieren. Weiterhin wurde die Streaming-Komponente aus AP7 im Fahrzeug validiert.
Metriken zur Bewertung der Demonstration	<ul style="list-style-type: none"> <li>• Güte der Szenarienprädiktion in urbanen Bereichen mit einer erhöhten Anzahl an nichtmotorisierten Verkehrsteilnehmern</li> <li>• Güte der Datenselektion. Korrektes Erkennen von risikoreichen Szenarien</li> <li>• Allgemein: Kritischer Schwellwert der Metriken muss durch die erfassten Szenarien vorhanden sein, sodass Kritikalitätsalgorithmen eine Datenaufzeichnung auslösen.</li> </ul>

Name des Demonstrators	<b>Unbemanntes Nutzfahrzeug im urbanen und ländlichen Bereich</b>
Verantwortlicher Partner	AVL Deutschland GmbH
Type des Demonstrators	Reales Fahrzeug als unbemanntes Nutzfahrzeug bzw. Arbeitsmaschine
Einsatzort des Demonstrators	Labor und reales Testfeld (nicht-öffentlich)
Beschreibung des Demonstrators	Unbemannte Nutzfahrzeuge (Unmanned Utility Vehicles - UUV) werden neben hochautomatisierten PKW und LKW in Zukunft in vielen Bereichen das Bild verändern. Insbesondere der unbemannte Überstellungs- oder sogar Arbeitsvorgang solcher Fahrzeuge im öffentlichen Raum stellt hohe Anforderungen an die Hersteller, deren Zulieferer und Dienstleister. Im Bild ist ein solches Fahrzeug als Technologiedemonstrator dargestellt (AVL e-Tractor),



Im UUV müssen für den sicheren Einsatz eine Vielzahl von Komponenten integriert und validiert werden, wie

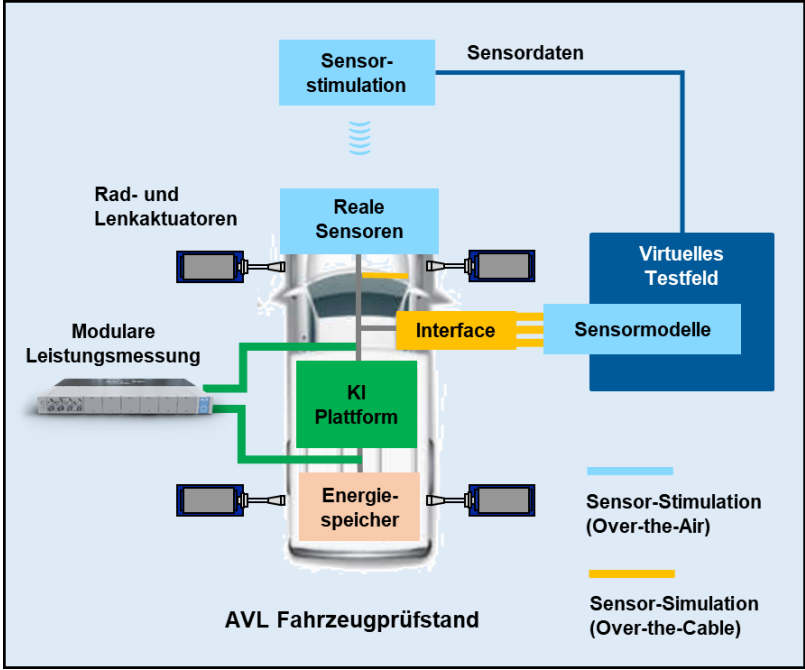
- Steuereinheiten für Energiespeicher, Antriebsstrang, Lenkung und Anbaugeräte
- Steuereinheiten für Umweltsensoren wie Kamera, Radar, LiDAR, Ultraschall, Lokalisierung
- Kommunikationseinheiten mit Lade- und Kontrollstationen
- Kommunikationseinheiten mit einer Leitstelle


Beschreibung der durchgeführten Versuche

Aufgrund der noch nicht vorhandenen Straßenzulassung des AVL e-Tractor wurde die Fahrzeugautomatisierung durch Messfahrzeuge vom Typ Audi Q5 und Audi A4 mit jeweils integrierten Sensorboxen emuliert.



Die fahrzeugspezifischen Basistechnologien wurden durch die im Projekt erarbeiteten KI-basierten Systeme im Fahrzeug als auch in der Leitstelle ergänzt und dann im Gesamtsystem am Fahrzeugprüfstand sowie im Realversuch validiert.

	
<p>Bezug zu den Arbeitszielen</p>	<p>Der Demonstrator wurde eingesetzt, um die entwickelten Systemarchitekturen (AP2), KI-Verfahren (AP3) und Metriken (AP1, AP3, AP4) im virtuellen Betrieb an real aufgezeichneten Szenarien zu erproben und zu verifizieren. Die Datenakquise aus realen Szenarien und mit realen Messdaten (AP5, AP6) sowie der Einsatz und Test der KI-Verfahren im simulierten Verkehr (AP7) waren integrale Bestandteile des im Projekt geplanten Demonstrators.</p>
<p>Metriken zur Bewertung der Demonstration</p>	<ul style="list-style-type: none"> <li>• Aufwand zur Integration und Validierung der KI-Systeme</li> <li>• Aufwand und Effizienz der Datenerfassung, -speicherung und -verarbeitung</li> <li>• Technologiereife / Einsatzbarkeit der KI-basierten Systeme</li> </ul>

Name des Demonstrators	<b>Versuchswagen im öffentlichen Raum</b>
Verantwortlicher Partner	LiangDao GmbH
Typ des Demonstrators	Reales Fahrzeug auf Basis eines VW Passat Kombi
Einsatzort des Demonstrators	Reales Testfeld, öffentlich: allgemeine Straßen im urbanen und ländlichen Bereich, sowie auf Autobahnen
Beschreibung des Demonstrators	 <p>Beim Demonstrator handelt es sich um ein Mess-Fahrzeug auf Basis eines VW Passat Kombi, welches im Rahmen von KisSME aufgebaut wurde. Der Messwagen verfügt über LiDAR-Sensoren, welche die Daten für die Objekt- und Szenarien-Detektion bereitstellen, RGB-Kameras zur Validierung der LiDAR-Rohdaten, eine CAN-Schnittstelle, um Ego-Daten des Fahrzeuges auszulesen, und GPS- und RTK-Antennen für die Lokalisierung. Die Technik für die Datenverarbeitung und -speicherung (OCU, Datalogger, Switch, Energieversorgung) ist im Kofferraum verbaut.</p> 
Beschreibung der durchgeführten Versuche	Das Messfahrzeug wurde im Rahmen des Projektes eingesetzt, um Daten für das Training der KI-Algorithmen zur Objekt- und Szenarienerkennung zu sammeln, sowie um die Algorithmen zu Testen und die Ergebnisse zu validieren. Die Daten wurden dabei auf gemeinsamen Testfahrten des Konsortiums, sowie auf eignen Testfahrten gesammelt. Auf weiteren Fahrten wurde die Echtzeit-Daten-

	übertragung zu Partner-Servern getestet.
Bezug zu den Arbeitszielen	Das im Rahmen von KIsSME aufgebaute Versuchsfahrzeug inklusive Sensorik und Datenbanksystem (AP5) wurde eingesetzt, um die entwickelten Systemarchitekturen (AP2), Prädiktionsverfahren (AP3, AP5) und Metriken (AP1, AP3) an realen Szenarien zu erproben und zu verifizieren. Zum Training der KI-Algorithmen wurden umfangreiche Daten auf Testfahrten gesammelt und einer Datenbank zugeführt (AP5, AP6). Die Daten wurden außerdem für Closed-Vehicle-in-the-Loop Simulationen (AP6) und die Generierung von ASAM-konformen Szenarien bereitgestellt.
Metriken zur Bewertung der Demonstration	<ul style="list-style-type: none"> <li>• Güte der Objekt- und Szenarienerkennung</li> <li>• Echtzeitfähigkeit der eingesetzten Algorithmen</li> <li>• Reduktion des benötigten Datenspeichers</li> </ul>

### 2.1.9 AP9 – Projektmanagement

Die Zusammenarbeit der verschiedenen Partner und Organisationseinheiten zur Erreichung eines gemeinsamen Zieles erforderte die Abstimmung und Koordination der individuellen Arbeiten. Ziel des Projektmanagements war die Schaffung von Rahmenbedingungen, die eine hohe Qualität der Arbeitsergebnisse ermöglichen. Zu Projektbeginn wurden die erforderlichen Aktivitäten geplant und abgestimmt. Während der Projektdurchführung wurde kontinuierlich der Fortschritt überprüft, bei Abweichungen wurde Korrekturmaßnahmen ergriffen und die Arbeitsergebnisse aktualisiert.

Zu Projektabschluss wurden die Arbeitsergebnisse evaluiert, dokumentiert und bei der Abschlussveranstaltung vorgestellt. Zur Dokumentation der Ergebnisse, welche im Vorhaben erzielt wurden, wurden halbjährlich Fortschrittsberichte erstellt. Jeder AP-Leiter verantwortete hierzu den Bericht zum jeweiligen Arbeitspaket.

Das Projekt KIsSME zeichnete sich somit durch eine intensive technische Zusammenarbeit der Konsortialpartner sowie einem Austausch mit den assoziierten Partnern aus. Insbesondere die technischen Abstimmungen erforderten die Anwesenheit der Projektmitarbeiter aller Partner zur erfolgreichen Durchführung des Vorhabens.

Für die Projektsteuerung wurden alle 4 Wochen Jour Fixe Termine gemeinsam mit allen Partnern per Videokonferenz durchgeführt. Im Gesamtkonsortium wurden die folgenden Treffen durchgeführt:

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

LiangDao leitete den für das Teilvorhaben besonders relevanten AP5. Zu diesem organisierte LiangDao zwischen März 2021 und Juni 2023 Regelmeeting, bis Juni 2021 im Abstand von etwa zwei Wochen, danach monatlich. Außerdem nahm LiangDao an den monatlichen Jour Fixe und Regelmeetings der weiteren APs teil, wenn für das Teilvorhaben relevante Punkte besprochen wurden, sowie an Workshops und AP übergreifenden Meetings, etwa zur Absprache von Arbeiten zur Kritikalitätsmetriken. Die Regelmeetings und Workshops wurden aufgrund der Covid-Pandemie und den verteilten Partnern überwiegend online abgehalten.

Zur Abschlussveranstaltung wurden, wie in Abbildung 21 dargestellt, die Demonstratorfahrzeuge präsentiert.




Abbildung 21: Demonstratorfahrzeuge bei der KisSME Abschlussveranstaltung

## 2.1.10 Zusammenfassung und Bewertung des Ergebnisses

### Gesamtvorhaben

Als Ziele wurde zu Beginn von Projekt KIsSME definiert:

- Mit Hilfe von KI soll die Identifikation von kritischen Fahrscenarien erfolgen.
- Entspricht ein Fahrscenario einem kritischen Testszenario, soll dieses für die Postanalyse der Daten entsprechend automatisiert markiert und Sensordaten wie auch ASAM OpenX konforme Szenariendaten extrahiert werden.
- Gleichzeitig sollen neue beispiellose, bisher nicht modellierte Testszenarien auf Basis der Beobachtungsdaten gelernt werden.
- Damit können in Zukunft Algorithmen für HAD/AD-Systeme effizienter trainiert werden.
- Durch die in KIsSME erzielten Erkenntnisse wären erweiterte Selbst-Diagnosen (EDR) bzw. Eventaufzeichnungen (EDR) möglich.
- Eine Evaluation der entwickelten Methoden soll anwendungsnah durch Einsatz unterschiedlicher automatisierter Fahrzeugsysteme im heterogenen urbanen Realbetrieb in mehreren Anwendungsfällen erfolgen.

Während des Projekts wurde die Ergebnisse zur Zielerreichung entsprechend der Projektplanung zu definierten Meilensteinen erarbeitet. In der folgenden Tabelle sind die drei Hauptmeilensteine dargestellt.

Meilenstein	Beschreibung	Termin	Verantw. Partner
H1	Abschluss der Analysen und Spezifikationen	Monat 9	Alle
H2	Abschluss der wesentlichen Aufbau- und Integrationsarbeiten an den Demonstratoren	Monat 20	Alle
H3	Abschluss der Versuche mit den Demonstratoren und Präsentation der Projektarbeiten	Monat 34	Alle

Bis zum Meilenstein H1 wurde aufgrund der unterschiedlichen Anforderungen der im Projekt betrachteten hochautomatisierten Fahrzeuge eine Unterscheidung in zwei Prozessvarianten erarbeitet wie in Abbildung 22 dargestellt.

#### „Massive Rohdaten“

- Umfangreiche Datenerfassung
- Spezielles Sensorset für definierte ODDs
- Szenarienabstraktion für Simulation optional
- Für unbemannte Fahrzeuge schwierig bis unmöglich

#### „Geringe Rohdaten“

- Einfachere Datenerfassung
- Beliebige Sensorset für Vielzahl an ODDs
- Szenarienabstraktion für Simulation zwingend erforderlich
- Für grosse Fahrzeugvarianz möglich



Abbildung 22 Prozessvarianten zur Datenerfassung

Während der Prozess „Massive Rohdaten“ bei Fahrzeug mit großen Flotten von typischerweise PKW mit identischer Sensorausstattung zum Einsatz kommt, wird der Prozess „Geringe Rohdaten“ bei Kleinserien aus dem Bereich der Nutzfahrzeuge und mobilen Maschinen angewendet.

Das Training der KI-Anwendung erfolgt im Prozess „Massive Rohdaten“ auf den realen Sensordaten (Abbildung 23), während im Prozess „Geringe Rohdaten“ das Training auf virtuellen Sensordaten erfolgt (Abbildung 24).

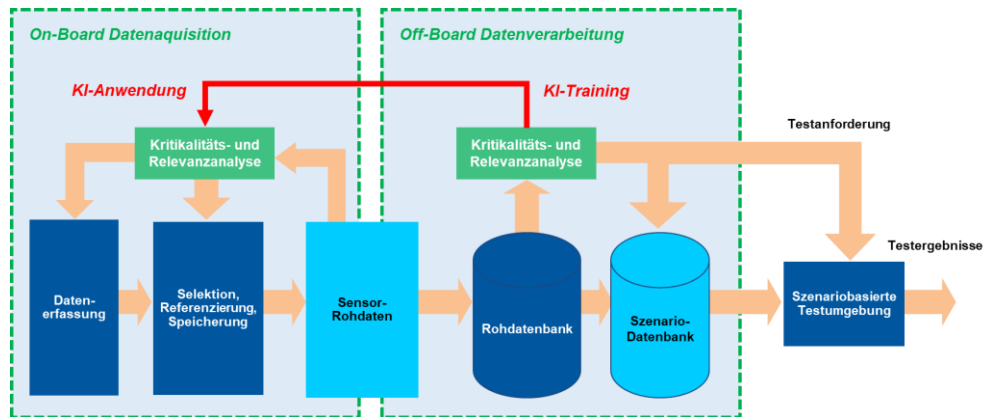


Abbildung 23: Prozess mit massiven Rohdaten

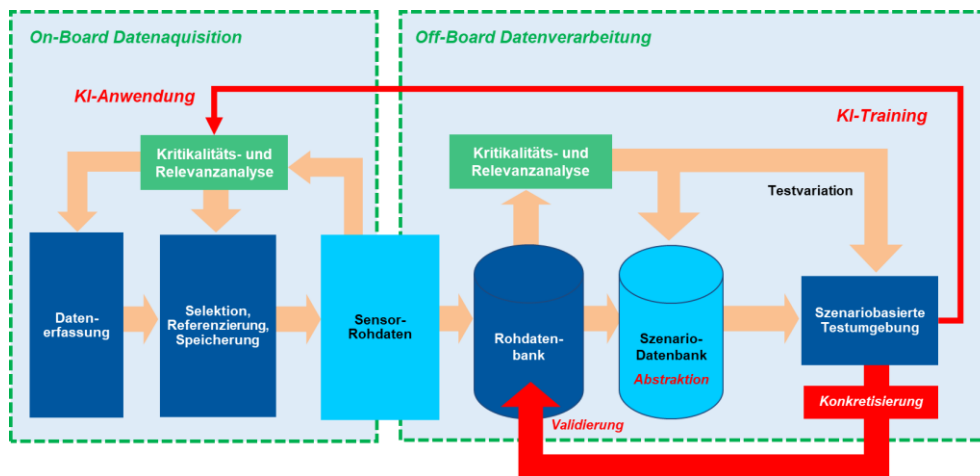


Abbildung 24: Prozess mit geringen Rohdaten

Bis zum Meilenstein H2 wurden von den Partnern unterschiedliche Simulationsumgebungen aufgebaut, um einerseits Metriken zu Bewertung von kritischen Szenarien anzuwenden, als auch die Datenerfassung in realen Szenarien in einer virtuellen Umgebung darstellen zu können (Abbildung 25).



Abbildung 25: Simulationsumgebung für die Datenerfassung. Beim Meilenstein H3 wurden von den Partnern die erarbeiteten Ergebnisse an dem in Abbildung 26 dargestellten Datenfluss zur Aufzeichnung von Szenarien dargestellt (KisSME-Pipeline).

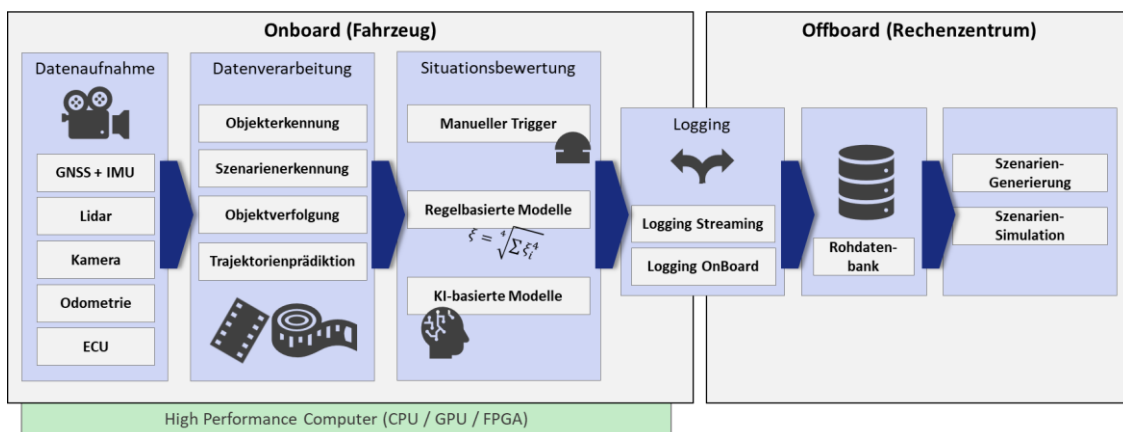


Abbildung 26: Datenfluss zur Erfassung relevanter bzw. kritischer Szenarien

## Teilvorhaben

Die Aufgaben des Teilvorhabens von LiangDao decken zu einem Großteil den OnBoard-Teil der Pipeline ab, wie auch Abschnitte auf der OffBoard-Seite. Im Rahmen des Vorhabens wurde ein Versuchswagen aufgebaut, mit einem LiDAR als Hauptsystem für die Objekt- und Szenarienerkennung, einem CAN-Bus-Zugang für das Auslesen von Fahrzeug-Daten, GPS/RTK Antennen (+Komponenten) für die genaue Positionierung des Ego-Fahrzeugs, einem RGB-Kamerasystem welches Referenzdaten für das Labeling der Trainingsdaten liefert, sowie ein OnBoard IT-System, inklusive Datenlogger, Switch und OCU für die Verarbeitung der Daten inklusive Objekt- und Szenarienerkennung, Triggerfunktionen (OnBoard-Teil der Pipeline).

Außerdem wurde ein Datenzentrum am Entwicklungszentrum von LiangDao in Berlin aufgebaut, für das Speichern und Verarbeiten der Trainingsdaten, inklusive Labeling, und für Entwicklung und Training der Objekt- und Szenarienerkennung basierend auf KI-Algorithmen (OffBoard-Teil der Pipeline).

Mithilfe der aufgebauten Infrastruktur entwickelte LiangDao die angestrebten KI-basierten Algorithmen für echtzeitfähige Objekt- und Szenarienerkennung und integrierte sie in die

gemeinsam erarbeitete KIsSME Pipeline, d.h. in das Versuchsfahrzeug. Die LiangDao eigene Verarbeitungskette für die automatisierte Szenarienerkennung wurde hinsichtlich datenschutzrechtlicher Gesetzgebung überprüft und als unbedenklich eingestuft, da diese nur auf Daten beruhen, die weder Personen identifizierbar noch KFZ-Kennzeichen auslesbar machen (LiDAR-Punktwolken).

Während im Rahmen des Teilvorhabens Szenariengenerierung und -simulation nicht zu den Aufgaben von LiangDao gehörte wurden entsprechende Arbeiten von anderen Partnern im Projekt durch die Weitergabe von Daten und eines offenen Austausches bestmöglich unterstützt.

Die Arbeiten erfolgten insgesamt in enger Abstimmung mit den Partnern, um die Kompatibilität einzelner Komponenten der KIsSME Pipeline untereinander zu gewährleisten, aber auch um ein möglichst offenes System basierend auf weit verbreiteten Standards zu entwickeln.

### Erfolgsnachweis

Die Erreichung der in der Vorhabensbeschreibung von Projekt KIsSME definierten Teilzeile aus Kapitel 2.1 wurden zu Projektende entsprechend den folgenden Indikatoren im Teilvorhaben wie auch im Gesamtvorhaben nachgewiesen.

### Performanz:

Für die Szenarienerkennung in Echtzeit ist es nötig, dass die gesamte Verarbeitungskette für ein einzelnes Frame abgeschlossen ist, bevor das nächste Frame vom Sensor bereitgestellt wird. Im Falle des von LiangDao verwendeten LiDAR belief sich die Frame-Rate auf 10 fps, womit die Verarbeitungskette 100ms hat, um das Frame zu verarbeiten. Dieser Wert konnte klar unterboten werden, siehe Tabelle 1. Die Werte sollen im Nachgang von KIsSME weiter verbessert werden.

	Benötigte Verarbeitungszeit	Erreichte Verarbeitungszeit
Wert	<100ms	<77ms

Tabelle 1: Performanz der Objekterkennung

### Qualität:

Indikator ist die Genauigkeit der Klassifizierung der Objekte und der Szenarien. Zu den am meisten eingesetzten Indikatoren zählen *Precision* und *Recall*. *Precision* ist das Verhältnis der korrekt erkannten Objekte/Szenarien (*true positive*) gegenüber aller erkannten Objekte/Szenarien (*true positive + false positive*). *Recall* beschreibt dagegen das Verhältnis der korrekt erkannten Objekte/Szenarien gegenüber aller real vorhandenen Objekte/Szenarien (*true positive + false negative*). In beiden Fällen ist eine höhere Prozentzahl besser. Zu Projektende konnten bei LiangDao die in Tabelle 2 dargestellte Werte erzielt werden. Dabei wurden für die Objekterkennung die Auswertung eines Referenzszenarios herangezogen, für die Szenarienerkennung dagegen die minimalen Werte aller in Betracht gezogenen Szenarien. Die Werte sollen im Nachgang von KIsSME weiter verbessert werden.

Parameter	Objekterkennung (spezifisches Szenario)	Szenarienerkennung (alle verarbeiteten)
Precision	99,4%	>85%
Recall	90%	>80%

Tabelle 2: Qualität der Klassifizierung

### Effizienz:

Indikator ist die Reduktion der zu speichernden Daten durch szenarienbasiertes, selektives Logging. Die Reduktion hängt während der Aufnahmen u.a. davon ab auf wie viele Szenarien geloggt werden soll bzw. kann und wie häufig sie auftreten. Ein Wert der sehr stark von der Straßenart und weiteren Parametern abhängt. Zur Veranschaulichung ist hier ein Beispiel gewählt bei dem auf nur ein Szenario, Cut-In von Fremdfahrzeugen vor dem Ego-Fahrzeug, geloggt wird. Zur Auswertung wurden Fahrten mit einer Gesamtlänge von 1.000km auf der Berliner Stadtautobahn herangezogen, die Durchschnittsgeschwindigkeit des Ego-Fahrzeugs betrug 80km/h (je langsamer, desto mehr Cut-In-Szenarien). Die durchschnittliche Länge der Cut-Ins war 5,7 Sekunden, mit Zeitpuffern wurden im Schnitt 12 Sekunden aufgezeichnet. Durch das szenarienselektive Aufnehmen konnte die Datenmenge um 90 % reduziert werden, siehe Tabelle 3 links.

Im Gesamtvorhaben über die gesamte KIsSME-Pipeline hinweg konnte eine Reduktion um eine weitere Größenordnung erzielt werden, siehe Tabelle 3 rechts, da die vorselektierten Daten von MindMotiv in ein eigen entwickeltes, OpenX-konformes Format für Szenariendaten umgewandelt wurden.

	Durch selektive Aufnahme (LiangDao)	Durch Umwandlung in spezielles Szenarienformat (von Partner)
Reduktion	~90%	~95%

Tabelle 3 Datenreduktion im Rahmen von KIsSME. Links: durch selektive Aufnahme für ein Referenzszenario (LiangDao), rechts: durchschnittliche durch Umwandlung in ein neu entwickeltes OpenX-konformes Format für Szenariendaten.

### Datenschutz:

Durch die Wahl von einem LiDAR-Daten als Ausgangsmaterial für von LiangDao entwickelte Lösung für KI-basierte Objekt und Szenarienerkennung, werden wie von offizieller Seite bestätigt, siehe AP3, keine datenschutzrelevanten Informationen erfasst.

Da einige Partner jedoch auch auf RGB-Kamera-Daten setzen, wurde von ihnen im Projekt an automatisierter Identifikation von datenschutz-relevanten Szenarienelementen in komplexen Szenarien auf Einzelbildebene gearbeitet. Zu Projektende konnten auf einem HPC Server die in Tabelle 4 ersichtlichen Durchschnittswerte bei der Aufzeichnung von Kameradaten, Objekterkennung und gleichzeitiger Online-Anonymisierung erzielt werden.

Parameter	Mittelwert
Accuracy	> 93%
Execution Time Anonymization	17,7 ms
GPU Usage	16,71 %
GPU Memory	2 %
CPU Usage	8,5 %
RAM Usage	5 %



Tabelle 4: Szenarienerkennung und Anonymisierung

### Erkenntnisgewinn:

Indikator ist eine KI-basierte Erkennung von komplexen Szenarien. Letztendlich konnten projektübergreifend mehr als 100 komplexe Szenarien basierend auf realen Testfahrt Daten ausgewertet werden. In Abbildung 27 sind beispielhaft drei Szenarien im Bereich von Kreisverkehren ersichtlich.



Abbildung 27: Komplexe Szenarien in Kreisverkehren

## 2.2 Zahlenmäßiger Nachweis

Zu den wesentlichen Kostenfaktoren bei der LiangDao GmbH zählten die Personalkosten des wissenschaftlich-technischen Personals. Diese zeichnete sich verantwortlich für den Aufbau des Versuchswagens und der nachgelagerten Infrastruktur (Datenbank), die Entwicklung der KI-basierten Algorithmen und weiterer Softwarekomponenten und die Durchführung der Versuchsfahren zur Aufnahme von Trainingsdaten bzw. zum Testen und Validieren der Algorithmen. Die Sachmittel flossen zu einem Großteil in den Aufbau des Versuchswagens und der nachgelagerten Infrastruktur. Tabelle 5 gibt einen Überblick der wichtigsten Positionen des zahlenmäßigen Nachweises.

Kostenart	Kosten
Personalkosten	1.009.882,15 €
Materialkosten	71.735,34 €
Reisekosten	4.4457,23 €
Sonstige unmittelbare Vorhabenkosten	8.632,40 €
Gesamte Selbstkosten des Vorhabens	1.094.707,12 €

Tabelle 5 Tabelle zum zahlenmäßigen Nachweis

Die über die gesamte Projektlaufzeit angefallenen Kosten und Einzelpositionen sind im Detail und im Vergleich zur Vorkalkulation dem Verwendungsnachweis zu entnehmen.

## 2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Das Projektziel, sowie die damit verbundenen Aufgaben waren sowohl im Gesamt- wie auch im Teilvorhaben klar und durchdacht definiert und strukturiert. Im Verlauf des Projektes wurden keine irrelevanten Punkte oder Irrwege identifiziert. Die für den Erfolg in einem solch komplexen Projekt nötige Kommunikation mit den Partnern war ebenfalls zu jeder Zeit gegeben. Es gab keine fehlerhafte oder mangelnde Kommunikation, die in Folge zu unnötigen Arbeiten führte. Die durchgeführten Arbeiten waren daher zu jeder Zeit für die Erfüllung der Aufgaben und der eigentlichen Ziele nicht nur notwendig, sondern auch angemessen. Ohne die bereitgestellte Förderung durch das BMWK, sowie ohne das Netzwerk des Konsortiums wären weder die Arbeiten an sich noch die Erfüllung der Ziele der des Gesamt- und des Teilvorhabens möglich gewesen. Für eine Einschätzung der Erfüllung der gesetzten Ziele, siehe Punkt 2.1.10.

## 2.4 Voraussichtlicher Nutzen

Der Bereich Automotive Electronics Engineering ist eine sehr erfolgreiche Domäne der deutschen Wirtschaft. Zum einen ist sie Voraussetzung für die wirtschaftliche Entwicklung innerhalb der Fahrzeughersteller, aber auch in einem hochqualifizierten Dienstleistungsbereich, dem Automotive Engineering. Darüber hinaus sind deutsche SW-Toolhersteller für das Automotive Electronics Engineering Weltmarktführer, deren Position es zu halten, verbessern und auszubauen gilt.

Die automatische On-Board Selektion relevanter Daten im Rahmen der Erforschung, Entwicklung, Erprobung und Validierung ist ein Schlüsselfaktor für die Einführung des automatisierten Fahrens in höheren Automatisierungsstufen. Dies ist für eine kostengünstige Entwicklung als auch für einen sicheren Betrieb und somit für wirtschaftliche Geschäftsmodelle am Standort Deutschland wesentlich. Die im Projekt zentrale Leitanwendung von automatisierten Fahrfunktionen adressiert den besonders stark wachsenden Zukunftsmarkt automatisierter Fahrzeuge Level 4-5.

Das KIsSME-Projekt ermöglichte es LiangDao Kompetenzen und Infrastruktur aufzubauen, um die Konkurrenzfähigkeit im beschriebenen Marktsegment zu erhöhen und neue Marktfelder zu erschließen.

Genauer hat LiangDao mit Hilfe von KIsSME ein Versuchswagen und ein Datenzentrum aufgebaut, mit vollständiger Pipeline für das Aufnehmen und Verarbeiten von Trainingsdaten, sowie dem Testen und Validieren der hauseigenen Algorithmen für Objekt- und Szenarienerkennung, welche nun echtzeitfähig und KI-basiert sind. Die KI-basierten Algorithmen können direkt die zuvor verwendeten regelbasierten Algorithmen in Produkten von LiangDao ersetzen.

Die aufgebaute Infrastruktur erlaubt es die gewonnene Kompetenz in Zukunft wesentlich einfacher auszubauen als dies vor KIsSME der Fall war. Die verarbeiteten Daten werden dazu ASAM-OpenX-kompatibel gespeichert, womit sich eine hohe wirtschaftliche Anschlussfähigkeit ergibt und der Austausch mit Partnern erleichtert wird.

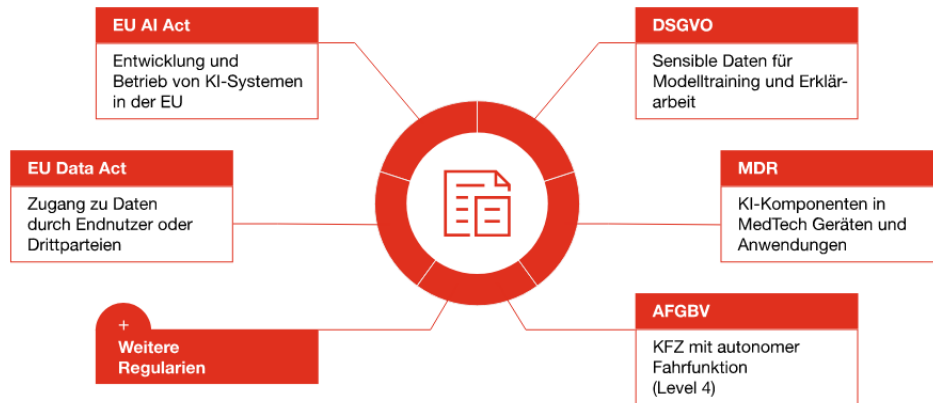
LiangDao wird die gewonnene Expertise und Infrastruktur (Algorithmen, Pipeline, Datenbank) auf den Geschäftsbereich stationärer Umfelderkassung, basierend auf Roadside Units, mit minimalen Anpassungen adaptieren. Die Infrastruktur beider Bereiche soll anschließend einheitlich weiterentwickelt werden.

Im Rahmen von KIsSME konnte ein vielversprechendes Netzwerk aus industriellen und wissenschaftlichen Partnern aufgebaut werden. Der Austausch soll für weitere Projekte genutzt werden.

Die Ergebnisse von KIsSME wurden durch Beiträge in Journalen und auf wissenschaftlichen Konferenzen einem breiten Fachpublikum zugänglich gemacht, womit auch ein weiterer Kreis an Interessenten von den Arbeiten des Konsortiums profitieren kann. LiangDao nutzt außerdem seine Mitgliedschaft in ASAM, um die Ergebnisse des Vorhabens zu verbreiten [22] und Veröffentlichung V11.

## 2.5 Fortschritte bei anderen Stellen

Seit Projektbeginn hat die Anwendung von KI in den unterschiedlichsten Domänen starke Fortschritte gemacht, die auch intensive gesellschaftliche Diskussionen angestoßen haben wie z.B. ChatGPT oder der EU AI Act. Dieser erwähnt explizit die automotiv Domäne mit Fahrfunktionen Level 4-5 in festgelegten Betriebsbereichen (Abbildung 28).



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

Abbildung 28: EU AI Act: Europäische KI-Regulierung und ihre Umsetzung

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

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

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

Im Forschungsprojekt AVEAS [19] wurden ebenfalls Kritikalitätsmetriken eingesetzt, um eine Datenbank kritischer Situationen aufzubauen. Die Abgrenzung zum Projekt KISsME ist in Abbildung 29 dargestellt.

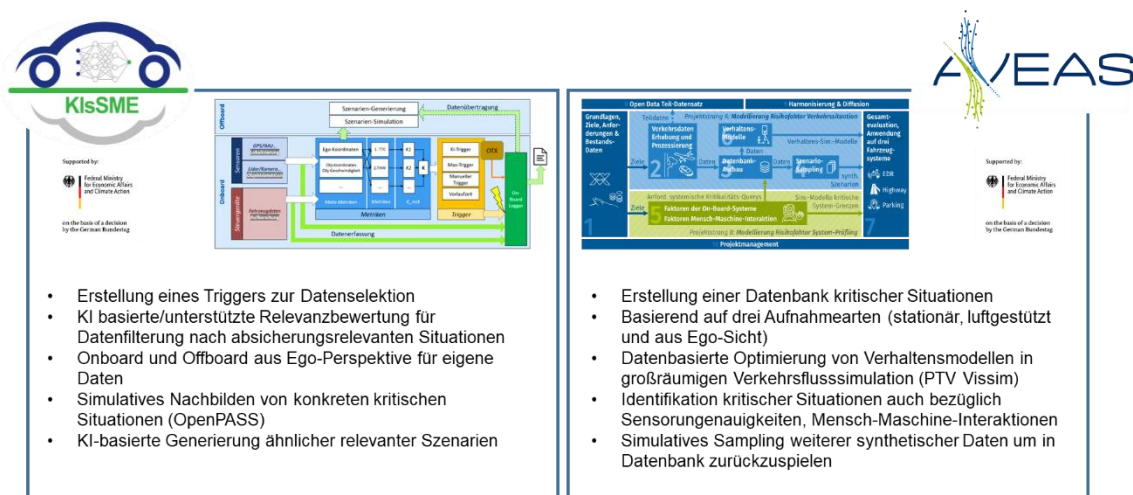


Abbildung 29: Abgrenzung der Projekte KISsME und AVEAS

## 2.6 Veröffentlichung der Ergebnisse

Während der gesamten Laufzeit von Projekt KIsSME erfolgte ein Austausch mit relevanten Akteuren zur Einführung des automatisierten Fahrens. Im Kapitel 2.6 sind alle während der Projektlaufzeit durchgeführten Veröffentlichungen und Vorträgen bei nationalen und internationalen Kongressen, Symposien und in Fachmagazinen aufgelistet. Dadurch konnten vielfältige Impulse und weitere Anforderungen in das Projekt eingebracht werden.

Bereits kurz nach Projektbeginn wurde von Partner FZI eine Projektwebsite erstellt und während des Projekts laufend aktualisiert [23]. In Abbildung 30 ist das von den Partnern erarbeitete Visual des Projekts KIsSME dargestellt.

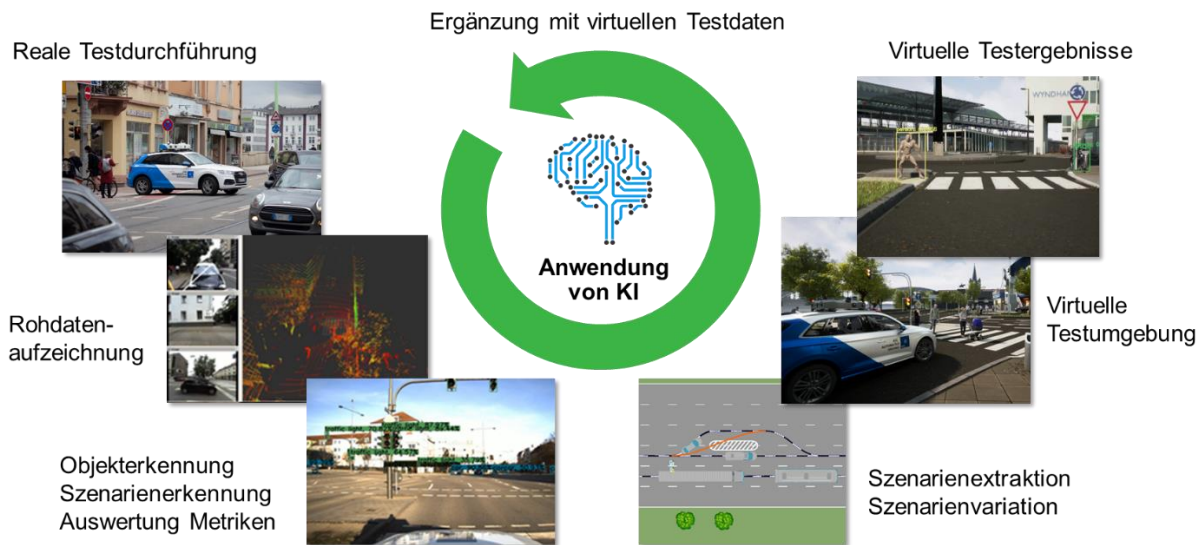


Abbildung 30: Visual von Projekt KIsSME

Alle Partner konnten während der Projektlaufzeit auf ihren Webseiten, über Pressemitteilungen sowie in ihren Beiträgen zu sozialen Medien über das Projekt KIsSME berichten. Als Beispiel ein Bericht über das Projekt und die Abschlussveranstaltung in [24].

**Die Veröffentlichungen von LiangDao (V1, V11) ist fett hervorgehoben.**

- V1 **Häring, I.; et. al.: Framework for safety assessment of autonomous driving functions up to SAE level 5 by self-learning iteratively improving control loops between development, safety and field life cycle phases. 2021 IEEE 17th International Conference on Intelligent Computer Communication and Processing (ICCP)**
- V2 Hantschel, F.; et. al.: From vehicle data to a holistic situation assessment - the practice-oriented KIsSME approach. 31st Aachen Colloquium Sustainable Mobility 2022
- V3 Hantschel, F.: „Das Forschungsprojekt KIsSME – von den Messwerten zu einer Szenarienbeschreibung mit Situationsbewertung und ASAM OpenX Standards“. IKAMeetups, Institut für Kraftfahrzeuge RWTH
- V4 Peccia F. et al, "Integration of a systolic array based hardware accelerator into a DNN operator auto-tuning framework", CODAI 2022 Workshop on Compilers, Deployment, and Tooling for Edge AI
- V5 Grimm, D.; et. al.: Holistic Graph-based Motion Prediction. 40th IEEE Conference on Robotics and Automation (ICRA 2023)
- V6 Uecker, M.; et. al.: Analyzing Deep Learning Representations of Point Clouds for RealTime In-Vehicle LiDAR Perception. NeurIPS 2022 Workshop on Machine Learning for Autonomous Driving
- V7 Rupalla, A.: Evolving Landscapes of Collaborative Testing for ADAS & AD. ASAM Test Specification Study Group Report 2022
- V8 Rupalla, A.; Hantschel, F.: Ergebnis der Analysen der ASAM Study Group zu etablierten und neueren Testverfahren im Lebenszyklus von hochautomatisierten und autonomer Fahrfunktionen. 15. Tagung Diagnose in mechatronischen Fahrzeugsystemen. Dresden 2022
- V9 ASAM SIM:Guide. Early addressing of ASAM standards in „KIsSME“, a BMWi-funded research project



- V10 Lüttner, F.; et.al.: Realistische Verkehrsflusssimulationen - Absicherung wird virtuell. Freiburger Dialog 2022
- V11 Eich, A; Shao, C.: Automatic large-scale scenario production and application. ASAM International Conference, Dresden 2022**
- V12 Schyr, C.: Project KIsSME - Artificial intelligence for the selective near-real-time recording of scenario and manoeuvre data when testing highly automated vehicles. Mercedes-Benz Data Night. Stuttgart 2022
- V13 Schyr, C.: Vernetzte Testfelder - Der Schlüssel zur erfolgreichen Entwicklung von hochautomatisierten Fahrzeugen. KoTAM – Veranstaltungsreihe zum Projekt Koordinierung der Testfelder Autonome Mobilität in Deutschland. Karlsruhe 2023
- V14 Schyr, C.: Projektvorstellung KIsSME. Stallwächterparty Berlin 2023
- V15 Fehling-Kaschek, M.; Lüttner, F.; Brockt, C.; Häring, I.; Schyr, C.: Automated detection of critical driving scenarios through AI-assisted algorithms. 10th Int. Symposium on Development Methodology, Wiesbaden 2023
- V17 Janjos, F, Dolgov, M, Zöllner, JM: StarNet: Joint action-space prediction with star graphs and implicit global-frame self-attention. 2022 IEEE Intelligent Vehicles Symposium (IV)
- V18 Janjos, F, Dolgov, M, Kuric, M, Shen, Y, Zöllner, JM: SAN: Scene Anchor Networks for Joint Action-Space Prediction. 2022 IEEE Intelligent Vehicles Symposium (IV)
- V19 Janjos, F, Keller, M, Dolgov, M, Zöllner, JM: Bridging the Gap Between Multi-Step and One-Shot Trajectory Prediction via Self-Supervision. 2023 IEEE Intelligent Vehicles Symposium (IV)
- V20 Pressemitteilung auf Bosch Research Website (30.11.2023):  
<https://www.bosch.com/de/forschung/aktuelles/ki-projekt-schaerft-die-sinne-vonautomatisierten-testfahrzeugen/>

### **Geplante Veröffentlichungen**

- V21 Janjos, F., Hallgarten, M, Knittel, A, Dolgov, M, Zell, A, Zöllner, JM: Conditional Unscented Autoencoders for Trajectory Prediction, geplant für IEEE Robotics and Automation Letters (RA-L)
- V22 Lüttner, F, Schmidt, D, Höpfner, H, etc: Assessing Critical Traffic Scenarios: a Modular Evaluation Framework, geplant für 2024

### 3 Literaturverzeichnis

- [1] Projekt PEGASUS: Etablierung von generell akzeptierten Gütekriterien, Werkzeugen und Methoden sowie Szenarien und Situationen zur Freigabe hochautomatisierter Fahrfunktionen, <https://www.pegasusprojekt.de>
- [2] Projekt SETLevel: Simulationsbasiertes Entwickeln und Testen von automatisierten Fahrzeugen, <https://setlevel.de>
- [3] Projekt VVMMethoden: Verifikations- und Validierungsmethoden automatisierter Fahrzeuge Level 4 und 5, <https://www.vvm-projekt.de/>
- [4] Page, Y.; Fahrenkrog, F.; Fiorentino, A.; Gwehenberger, J.; Helmer, T.; Lindman, M.; Camp, O.; Rooij, L.; Puch, S.; Fränzle, M.; Sander, U.; Wimmer, P. (2015) - A comprehensive and harmonized method for assessing the effectiveness of advanced driver assistance systems by virtual simulation: The P.E.A.R.S. initiative. 24th International Technical Conference on the Enhanced Safety of Vehicles.
- [5] Wang, L.; Vogt, T.; Dobberstein, J.; Bakker, J.; Jung, O.; Helmer, T.; Kates, R. (2018) - Multifunctional open-source simulation platform for development and functional validation of ADAS and automated driving. 135–148.
- [6] ECLIPSE OpenADx Working Group, <https://wiki.eclipse.org/OpenADx>
- [7] Cui, H. et al.: Multimodal Trajectory Predictions for Autonomous Driving using Deep Convolutional Networks. 2019 International Conference on Robotics and Automation (ICRA), 2019.
- [8] Tang, Y. et al.: Multiple Futures Prediction. 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), 2019.
- [9] Lehmann M., Bäuml M., Prokop G., Hamelow D. (2019). Use of a criticality metric for assessment of critical traffic situations as part of SePIA. In: Bargende M., Reuss HC., Wagner A., Wiedemann J. (eds) 19. Internationales Stuttgarter Symposium. Proceedings. Springer Vieweg, Wiesbaden.
- [10] Junietz, P., Schneider, J., & Winner, H. (2017). Metrik zur Bewertung der Kritikalität von Verkehrssituationen und-szenarien. In 11. Workshop Fahrerassistenzsysteme.
- [11] Eggert, J.: Predictive risk estimation for intelligent adas functions. 17th International IEEE Conference on Intelligent Transportation Systems (ITSC). 2014, S. 711–718
- [12] Schmidt, C. (2010). Hardware-in-the-Loop gestützte Entwicklungsplattform für Fahrerassistenzsysteme. Analyse und Generierung kritischer Verkehrsszenarien. Kassel University Press GmbH.
- [13] Kullmann, S. (2020). KI und DOE im Einsatz bei der Kalibrierung von elektrifizierten Antriebssträngen, Webinar, AVL List GmbH, 08.07.2020.
- [14] Karras, Tero, Samuli Laine, and Timo Aila. "A style-based generator architecture for generative adversarial networks." Proceedings of the IEEE conference on computer vision and pattern recognition. 2019.
- [15] Li, Chun-Liang, et al. "Point cloud gan." arXiv preprint arXiv:1810.05795 (2018).

- [16] Mukherjee, Amitangshu, et al. "Attribute-Controlled Traffic Data Augmentation Using Conditional Generative Models." CVPR Workshops. 2019.
- [17] Sallab, Ahmad El, et al. "LiDAR sensor modeling and data augmentation with GANs for autonomous driving." arXiv preprint arXiv:1905.07290 (2019).
- [18] Zhang, Chi, et al. "Generative adversarial network for synthetic time series data generation in smart grids." 2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm). IEEE, 2018.
- [19] Projekt AVEAS: Absicherungsrelevante Verkehrssituationen erheben, analysieren, simulieren, <https://aveas.org/>
- [20] Direkte Kommunikation via E-Mail mit Referat 4 Landesbeauftragte für Datenschutz und Informationsfreiheit Nordrhein-Westfalen vom 14.09.2022.
- [21] Lang, Alex H., et al. "PointPillars: Fast Encoders for Object Detection From Point Clouds" Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, S. 12697-12705.
- [22] Vorstellung von LiangDao Aktivitäten mit ASAM-Bezug. [Accelerating Data-driven Testing and Validation with OpenX standards in China and Germany \(asam.net\)](#),
- [23] Projekt KIsSME - Künstliche Intelligenz zur selektiven echtzeitnahen Aufnahme von Szenarien- und Manöverdaten bei der Erprobung von hochautomatisierten Fahrzeugen [www.kissme-projekt.de](http://www.kissme-projekt.de)
- [24] Projekt KIsSME - Abschlussveranstaltung vom 27.11.2023 <https://vimeo.com/896182515>

# Berichtsblatt

<b>1. ISBN oder ISSN</b>	<b>2. Berichtsart (Schlussbericht oder Veröffentlichung)</b> Schlussbericht
<b>3. Titel</b> Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien	
<b>4. Autor(en) [Name(n), Vorname(n)]</b> Eich, Andreas Ji, Yang	<b>5. Abschlussdatum des Vorhabens</b> 31.12.2023
	<b>6. Veröffentlichungsdatum</b> 27.06.2024
	<b>7. Form der Publikation</b> Sonstiges
<b>8. Durchführende Institution(en) (Name, Adresse)</b> LiangDao GmbH, Rosa-Bavarese-Straße 3 80639 München	<b>9. Ber.-Nr. Durchführende Institution</b>
	<b>10. Förderkennzeichen</b> 19A20026E
	<b>11. Seitenzahl</b> 66
<b>12. Fördernde Institution (Name, Adresse)</b> Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	<b>13. Literaturangaben</b> 24
	<b>14. Tabellen</b> 5
	<b>15. Abbildungen</b> 30
<b>16. DOI (Digital Object Identifier)</b> (noch nicht vergeben)	
<b>17. Vorgelegt bei (Titel, Ort, Datum)</b> TIB, Hannover, 27.6.2024	
<b>18. Kurzfassung</b> <p>Zum Nachweis der sicheren Funktion von hochautomatisierten Fahrzeugen werden nach aktuellem Stand der Technik fest definierte Szenarienkataloge zum manöverbezogenen Nachweis, sowie mehrere Millionen Fahrkilometer an Echtzeitdaten zum statistischen Nachweis herangezogen.</p> <p>Die Daten werden benötigt, um die durch KI getroffenen Entscheidungen validieren, verbessern und reproduzieren zu können, mit dem Ziel die notwendige Testabdeckung für zukünftige Funktionalitäten zu erreichen. Zur Entwicklung neuer Fahrzeuge mit Automatisierungslevel 4-5 ist es unabdingbar, den Aufwand zum Einfahren der Daten und dem Erstellen der Szenarienkataloge zu reduzieren.</p> <p>Das Projekt KIsSME hat eine Verarbeitungspipeline entwickelt, die es OnBoard-Systemen ermöglicht, relevante Szenarien in Echtzeit zu erkennen, selektiv Rohdaten aufzunehmen, zu verarbeiten, und die verarbeiteten Daten an eine automatisierte OffBoard-Aufbereitung für Szenarienkataloge weiterzuleiten. Die Pipeline automatisiert einen Großteil der Arbeitsschritte zum Erstellen der benötigten Datensätze, und reduziert gleichzeitig das Datenvolumen signifikant.</p> <p>Im Teilvorhaben von LiangDao, wurden KI-basierte, echtzeitfähige Algorithmen zur Objekt- und Szenarienerkennung entwickelt. Zum Teilvorhaben gehörten ebenfalls die nötigen (Vor)arbeiten, wie der Aufbau eines Versuchsfahrzeugs und eines Datenzentrums, das Einfahren von Daten für Training, Test und Validierung der Algorithmen, das Abklären datenschutzrechtlicher Fragen und die Einbettung in die Verarbeitungspipeline des Gesamtvorhabens. Der vorliegende Schlussbericht dokumentiert die Arbeiten und erreichten Ziele.</p> <p>Das KIsSME-Konzept wurde über Veröffentlichungen mit einem Fachpublikum geteilt. Das entwickelte Verfahren ist so der Allgemeinheit zugänglich und kann die Erstellung der benötigten Szenarienkataloge signifikant beschleunigen, bei gleichzeitiger drastischer Reduzierung der Ressourcen.</p>	
<b>19. Schlagwörter</b> LiDAR, Punktwolke, KI, automatisiertes Fahren, Objekterkennung, Szenarienerkennung, Szenariengenerierung, KI-basierte Objekterkennung, KI-basierte Szenarienerkennung	
<b>20. Verlag</b>	<b>21. Preis</b>

Nicht änderbare Endfassung mit der Kennung 2337253-14

## Document control sheet

<b>1. ISBN or ISSN</b>	<b>2. type of document (e.g. report, publication)</b> Veröffentlichung (Publikation)	
<b>3. title</b> Entwicklung KI-basiertes Verfahren zur Erkennung relevanter Szenarien		
<b>4. author(s) (family name, first name(s))</b> Eich, Andreas Ji, Yang	<b>5. end of project</b> 31.12.2023	
	<b>6. publication date</b> 27.06.2024	
	<b>7. form of publication</b> Sonstiges	
<b>8. performing organization(s) name, address</b> LiangDao GmbH Rosa-Bavarese-Straße 3 80639 München	<b>9. originators report no.</b>	
	<b>10. reference no.</b> 19A20026E	
	<b>11. no. of pages</b> 66	
<b>12. sponsoring agency (name, address)</b> Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	<b>13. no. of references</b> 24	
	<b>14. no. of tables</b> 5	
	<b>15. no. of figures</b> 30	
<b>16. DOI (Digital Object Identifier)</b> (not yet assigned)		
<b>17. presented at (title, place, date)</b> TIB, Hannover, 27.6.2024		
<b>18. abstract</b> <p>To prove the safe functioning of highly automated vehicles, the current state of the art uses firmly defined scenario catalogues for manoeuvre-related proof as well as several million kilometres of real-time data for statistical proof.</p> <p>The data is required to validate, improve and reproduce the decisions made by AI, with the aim of achieving the necessary test coverage for future functionalities. For the development of new vehicles with automation level 4-5, it is essential to reduce the effort required to collect the data and create the scenario catalogues.</p> <p>The KIsSME project has developed a processing pipeline that enables on-board systems to detect relevant scenarios in real time, selectively record and process raw data, and forward the processed data to an automated off-board preparation for scenario catalogues. The pipeline automates a large part of the steps for creating the required data sets and at the same time significantly reduces the volume of data.</p> <p>In LiangDao's sub-project, AI-based, real-time-capable algorithms for object and scenario recognition were developed. The sub-project also included the necessary (preliminary) work, such as the construction of a test vehicle and a data centre, the collection of data for training, testing and validation of the algorithms, the clarification of data protection issues and the embedding in the processing pipeline of the overall project. This final report documents the work carried out and the goals achieved.</p> <p>The KIsSME concept was shared with a professional audience via publications. The developed procedure is thus accessible to the general public and can significantly accelerate the creation of the required scenario catalogues, while at the same time drastically reducing the needed resources.</p>		
<b>19. keywords</b> AI, LiDAR, point cloud, automated vehicles, object detection, scenario detection, scenario generation, AI-based object detection, AI-based scenario detection		
<b>20. publisher</b>	<b>21. price</b>	

Nicht änderbare Endfassung mit der Kennung 2368227-10