Schlussbericht zum Teilvorhaben

Industrial Cloud-Datenmanagement und Analyseservices (Backend)

Verbundprojekt RDV – Real Driving Validation: Erweiterung der Überprüfbarkeit von Continuous SW Integration in Kommunikation mit Fahrzeugen im Feld

Förderkennzeichen	Verbundpartner
19A21051L	LiangDao GmbH

Laufzeit des Teilvorhabens	01.10.2023 bis 30.06.2025
Leiter des Teilvorhabens	Dr. Andreas Eich
Email/Telefon	andreas.eich@liangdao.de / +49 (0)173 7940 350
Version	1.0
Erstellungsdatum	19.11.2025

Finanziert von der Europäischen Union
NextGenerationEU

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

Inhaltsverzeichnis

Zusammenfassung 3
1 Kurze Darstellung 4
1.1 Aufgabenstellung 4
1.2 Voraussetzungen des Vorhabens 5
1.3 Planung und Ablauf des Vorhabens 8
1.4 Wissenschaftlicher und technischer Stand 9
1.5 Zusammenarbeit mit anderen Stellen 13
2 Eingehende Darstellung 14
2.1 Verwendung der Zuwendung und erzieltes Ergebnis 14
2.2 Wichtigste Positionen des zahlenmäßigen Nachweises 24
2.3 Notwendigkeit und Angemessenheit der Arbeit 24
2.4 Nutzen und Verwertbarkeit 24
2.5 Bekannt gewordener Fortschritt 25
2.6 Veröffentlichung der Ergebnisse 26
3 Literaturverzeichnis 27

ZUSAMMENFASSUNG

Eine kontinuierliche Qualitätsaussage über automatisierte Fahrfunktionen von Level 3 bis 5 auf Fahrzeugebene („Grey Box“) unter umfassender Berücksichtigung aller möglichen Szenarien, Umweltbedingungen und Verkehrsteilnehmer (Gesamtsystem) ist eine sehr große Herausforderung und bedarf einer zunehmenden Vernetzung sowie einem effizienten Wissenstransfer von Wirtschaft, Wissenschaft und Industrie.

Auf Grundlage realer Fahrdaten aus dem Feld sowie aus Hauptuntersuchungen wurde durch das Projekt Real Driving Validation (RDV) eine effiziente und sichere Methodik für OEM´s und Tier-1/Tier-2 Zulieferer zur Validierung von KI-basierten Fahrfunktionen zur Verfügung gestellt.

RDV nutzte stochastische Modelle und Ausfallwahrscheinlichkeiten, um anhand der realen Betriebszustände von Fahrzeugen im Feld kritische Szenarien gezielter und schneller identifizieren und testen zu können. Diese Szenarien können in digitale Ökosysteme wie GAIA-X oder zur Weiterentwicklung der industriellen Normung und Standardisierung genutzt werden.

Mittels Markov-Modell und numerischen Simulationsmethoden wurde zudem eine methodisch und analytisch-quantitativ abgesicherte Validierung der hochautomatisierten Fahrfunktionen (z.B. bei Softwareupdates) gewährleistet, wodurch optimierte Entwicklungs- und Zulassungsprozesse die Innovationszyklen durch Real Driving Validation beschleunigen.

Über ein AD-Referenzsystem für zukünftige „fail-operational” agierenden Fahrzeuggenerationen wurden anhand eines automatischen AD MW & Computing Test-Systems Erkenntnisse in Bezug auf Testbarkeit, speziell im Middleware-Segment des AD-Stacks und der OnBoard Datenkommunikation, gewonnen.

Die Aufgabe von LiangDao im Teilvorhaben „Industrial Cloud-Datenmanagement und Analyseservices (Backend)“ war die Entwicklung einer zentralen, Cloud-basierten Lösung, um für den RDV-Ansatz relevante Fahrzeugdaten in nahezu Echtzeit zu empfangen, zu analysieren, zu speichern und für Nutzer zur Verfügung zu stellen, und zwar sowohl den eigentlichen Datensatz als auch in einer visuell aufbereiteten Form. Der vorliegende Bericht fasst die Ergebnisse des Teilvorhabens zusammen.

1 Kurze Darstellung

1.1 Aufgabenstellung

Kern des Gesamtprojekts war die Ermöglichung einer kontinuierlichen Qualitätsaussage über automatisierte Fahrfunktionen auf Fahrzeugebene (Grey Box). Dies sollte unter umfassender Berücksichtigung von Fahrszenarien, Umweltbedingungen und aller Verkehrsteilnehmenden (Gesamtsystem) geschehen. Hierbei stand das Fahrzeug im Mittelpunkt. Für automatisierte Fahrfunktionen bedeutet dies, dass aufgrund komplexer und stark vernetzter Software – z.T. mit eigener Entscheidungsgewalt – die Prüfung mit klassischen Testverfahren zu lückenhaft ist. Lediglich die Reaktion der Fahrfunktion auf einzelne Situationen kann als sog. „Black Box" bewertet werden.

Ziel des Projektes war eine zustandsorientierte Bewertung automatisierter Fahrfunktionen basierend auf realen Fahrdaten, die in einem virtuellen Gesamtsystem modelliert werden. Hierzu gehört die Identifikation von Schwachstellten zur Entwicklung einer Testprozedur sowie die Überprüfung der Leistungsfähigkeit theoretischer Ansätze der Zuverlässigkeitsanalyse im Kontext des autonomen Fahrens. Der Wissenstransfer von theoretischen Analyseansätzen in die Industrie stellte ein weiteres Ziel des Vorhabens dar.

Durch intelligente und vernetzte Testmethoden sollte ein aktiver Beitrag zum Ressourcen- und Klimaschutz geliefert werden, der gleichzeitig einen Erkenntnistransfer zwischen der Wirtschaft und Wissenschaft sowie den mit der Überwachung beauftragten Organisationen erlaubt und somit die Zukunftsfähigkeit des Wirtschaftsstandorts Deutschland festigen kann.

Unterliegend ist hier auch der Wandel der Gesellschaft zu sehen, die sich neben neu auf dem Markt erscheinenden Fahrzeugen und intelligenter Mobilität auch mit Aspekten der Energiewende beschäftigen muss. Die Ergebnisse von RDV können in diesem Zusammenhang für eine höhere Akzeptanz in der Bevölkerung bei der Nutzung intelligenter Mobilitätskonzepte durch eine angepasste Testmethode sorgen. Diese trägt darüber hinaus zu einer Stärkung des Innovationsstandortes Deutschland und der deutschen Automobilindustrie sowie Zulieferindustrie bei.

Die Aufgabe von LiangDao im Teilvorhaben „Industrial Cloud-Datenmanagement und Analyseservices (Backend)" war die Entwicklung einer zentralen, Cloud-basierten Lösung, um für den RDV-Ansatz relevante Fahrzeugdaten in nahezu Echtzeit zu empfangen, zu analysieren, zu speichern und für Nutzer zur Verfügung zu stellen, und zwar sowohl den eigentlichen Datensatz als auch in einer visuell aufbereiteten Form.

1.2 VORAUSSETZUNGEN DES VORHABENS

Durch die Expertise der beteiligten Verbundpartner konnten, die im Projekt RDV definierten Aufgaben erfolgreich bearbeitet und ein neuer Stand der Technik erzielt werden.

Das Konsortium setzte sich final aus 6 Unternehmen, sowie 2 wissenschaftlichen Einrichtungen und 2 Prüforganisationen zusammen.

Partner	Kompetenzen und Erfahrung
DEKRA SE	DEKRA SE ist mit 26 Mio. Fahrzeugprüfungen jährlich weltweit der größte Prüfdienstleister für wiederkehrende Prüfungen und im Bereich Homologation und Technische Abnahme mit dem Automobil Test Center erfolgreich am Markt tätig. DEKRA ist u.a. engagiert im Projekt People Mover sowie im Prüffeld Lausitzring zu vernetztem autonomem Fahren. Ferner in der Standardisierungsentwicklung bzgl. nachhaltigem, sicherem und autonomem Fahren, u.a. im UNECE „World Forum for the Harmonization of Vehicle Regulations“, ACEA und OICA. DEKRA leitete das EU-Projekt FutureDRV und ist Partner der BMBF Projekte SEANCe und AHEAD. Innovative Lösungen im Gesamtfeld der Mobilität werden von DEKRA in vielen Bereichen gefördert und entwickelt. Die modernen Testzentren in Klettwitz und Malaga zeigen diese Entwicklung eindrucksvoll.
dSPACE GmbH	In das Vorhaben Real Driving Validation brachte dSPACE seine Kompetenzen als einer der führenden Anbieter von Simulations- und Validierungslösungen ein. Im Projekt war dSPACE insbesondere an der Bereitstellung und Anwendung von SiL-Simulationsumgebungen beteiligt, die für das Testing mittels Data Replay sowie zur Validierung eines Vehicle Dynamics Fahrzeugmodells eingesetzt wurden. Zudem wurde die Anwendung von Markov-Modellen zur Bewertung wetterbedingter Auslösebedingungen untersucht und ein statistischer Ansatz zur Quantifizierung unbekannter Szenarien in ADAS/AD-Systemen erarbeitet.
LiangDao GmbH	LiangDao ist ein KMU, welches unter anderem auf die Entwicklung und Nutzung intelligenter Sensorsysteme zur Testung und Validierung autonomer Fahrfunktionen spezialisiert ist. Seit der Firmengründung arbeitet LiangDao eng mit Kunden wie Volkswagen, Audi, BMW und Magna zusammen. Im Projekt RDV brachte das Unternehmen seine Expertise in der Informationsverarbeitung ein, um eine Cloud-basierte Datenmanagement und Analyse-Lösung zu entwickeln, die relevante Fahrzeugdaten empfängt, speichert, verarbeitet und über eine anpassbare Benutzeroberfläche bereitstellt.
TH Augsburg	Die Technische Hochschule Augsburg verfügt mit der Forschungsgruppe Driverless Mobility und dem Technologietransferzentrum (TTZ) Data Science und Autonome Systeme über umfassende Erfahrung im Bereich automatisiertes und autonomes Fahren. Schwerpunkte liegen in Sensordatenfusion,

Lokalisierung, Planung, Fahrzeugführung sowie Sicherheitsaspekten nach FuSi- und SOTIF-Standards.

Im Projekt verantwortet die THA die Entwicklung und Integration autonomer Fahrfunktionen auf Basis bestehender Softwaremodule, die hinsichtlich Echtzeitfähigkeit, Genauigkeit und Robustheit weiterentwickelt werden. Erfahrungen aus Projekten wie KoRA9, FAST, MCube und dem Autonomen Leichtbaufahrzeug IAA 2023 bilden die Grundlage für die erfolgreiche Umsetzung der Projektziele.

TÜV Nord Mobilität GmbH	Als Teil der TÜV NORD Mobilität GmbH & Co. KG arbeitet das Institut für Fahrzeugtechnik und Mobilität (IFM) seit sechs Jahrzehnten als innovativer und unabhängiger Ingenieurdienstleister auf nationaler, europäischer und weltweiter Ebene für Industrieunternehmen und Regierungsbehörden. Mit rund 200 Mitarbeitern verfügt das IFM über eine anerkannt hohe technische Fachkompetenz in den mechanischen, mechatronischen und elektronischen Systemen moderner Fahrzeuge und bietet ein breites Spektrum an Beratungs- und Prüfdienstleistungen auf dem Gebiet der Entwicklung, Validierung und Serienzulassung von Fahrzeugen. Als akkreditierter Dienstleister führt IFM Einzel-, Muster- und Typprüfungen durch und unterstützt seine Kunden im gesamten Typprüfungs-Prozess. An zahlreichen Richtlinien, Regelungen und Verordnungen der EU arbeitet IFM in Arbeitskreisen und Gremien mit. Als Spezialist für eingebettete Systeme, aktive Sicherheitstechnik und Vernetzungstechnologien im Automobil beteiligt sich das IFM an der Entwicklung, Standardisierung und Einführung neuer Technologien und Entwicklungsansätze.
TTTech Auto Germany GmbH	TTTech Auto Germany GmbH ist als Tochterunternehmen der TTTech Auto AG und liefert Sicherheitssoftware Plattformen und Integrationsdienstleistungen, die für hochautomatisiertes Fahren und autonome Fahrzeuge eingesetzt werden. Außerdem bietet das Unternehmen serienerprobte Softwarelösungen für “Autonomous Driving” (AD) an, die die “Time-to-Market" entscheidend verkürzen und die Anwendersoftware-Entwicklung maßgeblich unterstützen. Durch den Einsatz des TADE Know-Hows können Software-Komponenten bereits vor der Verfügbarkeit der eigentlichen Zielhardware getestet und validiert werden. TADE hat sich auf diesem Gebiet einen internationalen Ruf als Lieferant von ADAS-Serienprodukten und Sicherheitstechnologien erarbeitet. Zusätzlich verfügt das Unternehmen über langjährige Erfahrung im Management und der Abwicklung von Förderprojekten zur Reduktion des F&E Risikos.
Fraunhofer EMI	Das Fraunhofer EMI brachte umfassende Expertise in quantitativen Risiko- und Resilienzanalysen sowie funktionalen Sicherheitsanalysen (IEC 61508, ISO 26262) in das Projekt ein. Es arbeitete in

sicherheitskritischen Automotive-Projekten wie DINA, FSEM und EVERSAFE, insbesondere im Bereich autonomer Schutzsysteme.

Ein erweiterter Markov-Ansatz zum Sicherheitsnachweis für autonomes Fahren wurde angewandt. Zudem untersuchte EMI die Sicherheit automatischer Inspektionsroboter und die Kollisionsvermeidung von Drohnen. Im Projekt KIsSME nutzte EMI Machine Learning und Künstliche Intelligenz zur Verbesserung und Validierung kritischer Szenarien für autonome Fahrzeuge.

Die Institution verfügt über Forschungsgruppen zu Sicherheits- und Effizienzanalysen sowie zur Sicherheit selbstlernender Systeme. Im Vorhaben Real Driving Validation flossen die Kompetenzen in Markov-Modellierung und Machine Learning in die Optimierung der Berechnungen ein.

IQZ GmbH

Das Institut für Qualitäts- und Zuverlässigkeitsmanagement GmbH (kurz IQZ) mit Sitzen in Wuppertal und Hamburg ist eine KMU-Ausgründung (seit 2012) der Bergischen Universität Wuppertal mit den Schwerpunkten Zuverlässigkeits-, Sicherheits- und Qualitätsmanagement. Das Branchenspektrum umfasst die Automobil- und Luftfahrtindustrie, Energietechnik (insb. erneuerbare Energien im Sektor Windenergie) und Maschinensicherheit. Die angebotenen Leistungen umfassen den kompletten Produktlebenszyklus von Design und Entwicklung (z.B. Design for Reliability und Zuverlässigkeitsprozesse im PEP) über den Betrieb (Garantie- und Gewährleistungsthemen sowie Felddatenanalysen) bis hin zum PhaseOut (Smart Maintenance und PLC-Optimierung).

JHP GmbH

JHP stellt statistische Ansätze aus dem Bereich der Zuverlässigkeitstechnik für technische Fragestellungen verschiedener Technologien bereit. JHP führte im RDV-Projekt statistische Auswertungen von Validierungsdaten von Perzeptionsalgorithmen sowie von Feldvalidierungsdaten autonomer Fahrzeuge durch. Es wurde auch ein statistischer Ansatz zur Risikoquantifizierung bisher unbekannter Fahrszenarien erarbeitet.

RA Consulting GmbH

Die RA Consulting GmbH (RAC) konnte in RDV sowohl Kenntnisse zu den bestehenden, den zahlreichen aktuell laufenden und neuen ASAM Standardisierungsarbeiten und -initiativen einbringen. In AP6 wurde exemplarisch ein System für die Kommunikation und das Taskmanagement zwischen Fahrzeug und der Cloud realisiert, um Validierungen im Feld in unterschiedlichen Szenarien zu ermöglichen. In AP9 wurde dieses dann evaluiert.

1.3 Planung und Ablauf des Vorhabens

Im Projekt RDV wurde ein strukturiertes Vorgehensmodell verfolgt, das sich aus 11 Arbeitspaketen (AP) zusammensetzt. Zur Projektsteuerung wurden jedem Arbeitspaket konkrete interne Meilensteine zugewiesen, die den Fortschritt und die Zielerreichung systematisch überwachen. Wobei die Bewertung zum Projektabschluss über KPIs basierend auf Technologiereifegraden (t*echnology readiness levels*, TRLs) erfolgte, siehe Abschnitt 2.1.

- AP0 – Organisation und High-Level Architektur (Leitung dSPACE GmbH)
- AP1 – Fahrzeugdatenmanagement (Leitung TTTech Auto Germany GmbH)
- AP2 – Definition Gesamtzustandsraum (Leitung IQZ GmbH)
- AP3 – Fehlermodellierung & Absicherung (Leitung JHP GmbH)
- AP4 – Expertenwissen (Leitung DEKRA SE)
- AP5 – Industrial Cloud-Datenmanagement und -Analyseservices (Leitung LiangDao GmbH)
- AP6 – Datenaufbereitung und Vereinheitlichung für Kommunikation SZT und Cloud sowie Telematik-Middle-Ware (RAC)
- AP7 – Gesamtsicherheitsmodellierung und Nachweisbedarfsbestimmung (EMI)
- AP8 – XiL-Simulation (dSPACE)
- AP9.1 – Testfahrten auf dem Testfeld autonomes Fahren Baden-Württemberg mit integriertem TelTaKo-S und Leitsystem TAF (Leitung RA Consulting GmbH)
- AP9.2 – Aufbau und Integration Forschungsfahrzeug / Proving Ground (Leitung THA Hochschule Augsburg)
- AP10 – Prozess zum Sicherheitsnachweis im Entwicklungszyklus für hochautomatisierte Fahrzeuge (Leitung THA Hochschule Augsburg)
- AP11 – Erforschung und Beiträge für die nächsten Generationen AD Systeme SAE Level 4&5, Referenzsystem und automatisches Testen (Leitung TTTech Auto Germany GmbH)

Im September 2023 ist der ursprüngliche Konsortialführer Horiba aus dem Projekt ausgeschieden. Diese Veränderung markierte einen zentralen Wendepunkt im Projektverlauf. Neben der Aufnahme der neuen Partner TH Augsburg und LiangDao - sowie der Übernahme der Projektkoordination durch dSPACE unterstützt durch Fraunhofer EMI - wurde das Vorhaben inhaltlich überarbeitet und strategisch neu ausgerichtet. Ziel war es, die Projektstruktur zu vereinfachen und die inhaltliche Kohärenz zu stärken.

LiangDao übernahm die APs 5 und 1.3, welche wesentlich für die Arbeiten im vorliegenden Teilvorhaben waren, in leicht überarbeiteter Form.

Im Rahmen dieser Neuausrichtung wurden fünf konkrete Use Cases definiert, die die Aktivitäten der verschiedenen Arbeitspakete thematisch bündeln und eine zielgerichtete Umsetzung der Projektziele ermöglichen sollten. Diese Use Cases, wie in Abbildung 1 dargestellt, erleichterten zusätzlich sowohl die interne Koordination als auch die externe Kommunikation des Projektfortschritts.

LiangDao war zentraler Bestandteil von Use Case 1 und leistete für Use Case 3 unterstützende Arbeiten.

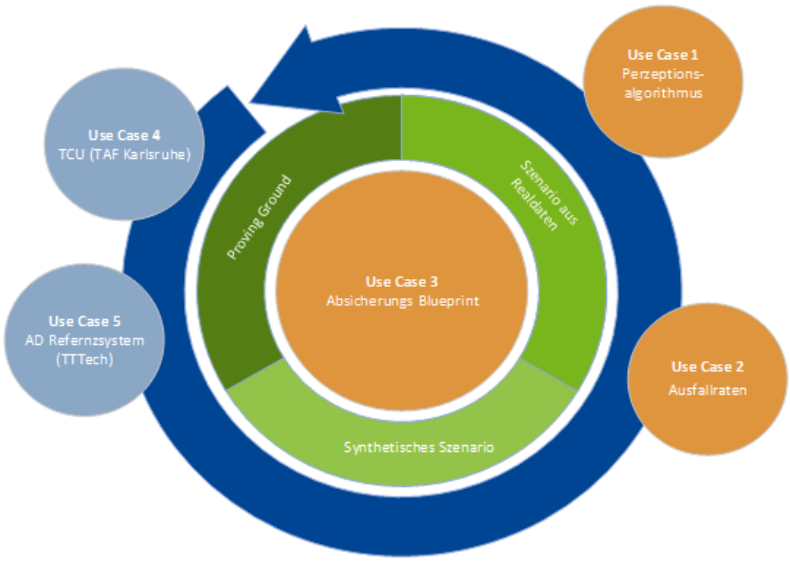

Abbildung 1: Übersicht Use Cases 1-5.

1.4 Wissenschaftlicher und technischer Stand

Die nachfolgende Darstellung beschreibt den wissenschaftlichen Stand des Gesamtvorhabens zum Projektbeginn:

Wie auch in anderen Hochtechnologiebranchen, z.B. Luft- und Raumfahrt, wird die Automobilindustrie zunehmend wirtschaftlich herausgefordert; immer mehr autonome Fahrfunktionen müssen realisiert werden. Die Aufwände für Entwicklung und Nachweis der Sicherheit von Systemen mit hohem Softwareanteil nehmen deutlich zu und müssen in einem vertretbaren zeitlichen und wirtschaftlichen Rahmen bleiben.

Der RDV-Ansatz ermöglicht eine analytische Gesamtsystembetrachtung dieser hochautomatisierten Systeme. Dies ist ein neuer Ansatz, da bisher nicht versucht wurde, analytische Gesamtsystemmodellierung und -simulation für Fahrzeuge mit autonomer Fahrfunktion durchzuführen. Die klassische Verwendung tabellarischer Gefährdungs- und Risikoanalysen (Hazard and Risk Analysis, HARA) (z.B. (Macher et al. 2016)), unterstützt durch FMEDA und Fehlerbaumanalysen (Fault Tree Analysis, FTA) für die Bestimmung von Häufigkeiten von ausgewählten einzelnen Ereignissen in vorgegebenen Szenarien (z.B. (Winkle 2016)), reicht jedoch nicht aus und führt auch zu unüberschaubarem zeitlichem Aufwand. Diese klassischen Methoden eignen sich nur wenig, um den großen dynamischen Zustandsraum und mögliche (unbeabsichtigte) Zustandsübergänge für teil- und vollautonome selbstlernende, auch Pfad-abhängige Fahrassistenz- und Fahrfunktionen abzudecken. Die Verwaltung von Gesamtrisiken und Anforderungen an Teilsysteme abzuleiten, erscheint analytisch, experimentell kaum darstellbar. Vor allem kosteneffiziente, quantitativ/simulativ wie quantitativ überprüfbare Ergebnisse bereits in frühen Phasen der Entwicklung sind ebenfalls nicht darstellbar.

Mit dem RDV-Vorgehensmodell können anerkannte, strukturierte Vorgehensweisen im Bereich V&V und Testmethoden generiert werden, um mit Hilfe von Simulationen von Modellen, Software, Hardware (XiL) bis hin zu Fahrzeug(-funktionen) in-the-Loop (ViL) und Fahrzeugtests Nachweislücken systematisch zu schließen (Bock et al. 2007) (Bock et al. 2008) (Huang et al. 2016) (Rosique et al. 2019).

Unter anderem diese und weitere Einschränkungen sollen im Rahmen des Forschungsprojekts erheblich aufgehoben werden, wobei gleichzeitig die Vorteile analytischer Vorgehensweisen weitgehend erhalten

bleiben. Dies betrifft vor allem den Vollständigkeitsanspruch, d.h. die Abdeckung aller physikalisch-technisch-organisatorisch möglichen Zustände (auf ausreichend abstrakter Ebene), auch bisher noch unbeobachteter Zustände (unexampled events, unknown threats) und schließlich die konzeptionelle Verstehbarkeit und Kompaktheit der Modellierung. Die Vollständigkeit der Modellierung wird insbesondere dadurch erreicht, dass nicht nur das Fahrzeug selbst, sondern auch Fahrzeuginsassen, Fahrumgebung, andere (verwundbare) Verkehrsteilnehmer, Wetter- und Straßenbedingungen, Schnittstellen zu externen Systemen (z.B. Verkehrsinformationssysteme) in der Gesamtsystemmodellierung berücksichtigt werden. Diese Modellierung soll mit ML/KI-Ansätzen auch hybrid erweitert werden. Der Fokus soll auf einer minimal ausreichenden Erweiterung mit hoher Anschlussfähigkeit für die Erfüllung von Zulassungen, Erweiterungen und (SW) Updates neuer autonomer Fahrfunktionen liegen.

Weiterhin sollen in der erweiterten Gesamtsystemanalyse ähnlich wie in klassischen Systemanalysen Vorwissen bzgl. Fahrzeugarchitekturen, in Form von (online) Daten verwendet werden können, z.B. in der Praxis bestätigte (zeitabhängige) Ausfallraten von HW, datengetriebene Ausfall- und Reparaturmodelle für Subsysteme, Modelle für Fail-Safe-Architekturen und Back-Up-Notsysteme. Hierzu sollen wiederum entsprechende ML/KI unterstützte Ansätze entwickelt werden.

Die Gesamtsystemmodellierung und -simulation soll Hinweise auf den Bedarf höherer oder geringerer Auflösung der Modellierung, sowie die Anbindung an reale Fahrzeugmodellierung entsprechend Stand der Technik ermöglichen. So ist insbesondere eine eindeutige Beziehung zwischen der Gesamtzustands-Modellierung und einer SysML-Modellierung des Fahrzeugs und der Umgebung anzustreben. Zusätzlich sind eindeutige Bezüge zu bestehenden bzw. sich entwickelnden Standards aus der ASAM-Familie, ISO und IEC herzustellen bzw. auf diesen Standards aufzubauen, um die unmittelbare Einsatzfähigkeit des Ansatzes in frühen Phasen von Entwicklungen, für Zulassungen, Erweiterungen und bei erforderlichen (SW) Updates sicherzustellen sowie die dahinterliegenden Entwicklungsprozesse für das Fahrzeug massiv zu unterstützen.

Umso mehr sind Ansätze interessant, die es ermöglichen die Zeitabhängigkeit von Zuständen darzustellen. Speziell Markov-Modelle wurden bereits erfolgreich im Kontext der Bewertung autonome Fahrfunktionen eingesetzt, z.B. (Cherfi et al. 2014) (Bondesson 2018) (Satsrisakul 2018) (Heinrich et al. 2017) (Nyberg 2018) (Gheraibia et al. 2018) (Kaalen 2019) (Kaalen et al. 2019). Jedoch werden starke Vereinfachungen angenommen, u.a. konstante Übergangswahrscheinlichkeiten, keine industrietaugliche Auflösung der Modelle, einheitliche Arten von Übergangsarten, Beschränkung auf eine Modellart, fehlende Skalierung der Modellierung.

Nachfolgende Veröffentlichungen weisen ebenso in die Richtung der erforderlichen und geplanten Erweiterungen, jedoch weitgehend in anderen industriellen Kontexten: (Gomes et al. 2012) für die Verknüpfung von Systemmodellierung und zu erweiternder Makov-Modellierung, (Talebberrouane et al. 2016) für die Verwendung von Monte-Carlo Simulation zusammen mit Markov-Ansätzen, um Unsicherheiten zu bestimmen sowie (Yevkin 2016) für die Erweiterung der klassischen FTA mit Hilfe von Markov-Modellen bzw. der Äquivalenz derselben.

Neben der Verwendung von Markov-Modellen zur zustandsbasierten Systemsimulation sowie der Bestimmung von Kenngrößen zur Zuverlässigkeit und Sicherheit gibt es weiterhin zahlreiche Anwendungsmöglichkeiten. Nachfolgend werden einige neuere Beispiele aufgeführt, die zum Teil auch Machine Learning verwenden. (Aljohani et al. 2021) nutzt Markov-Ketten und Deep Reinforced Learning, um den Energieverbrauch von Elektrofahrzeugen zu verringern, (Fragapane et al. 2021) für die Planung und Steuerung von autonomen mobilen Robotern mit Markov-Ketten, (Papadopoulos et al. 2019) klassifiziert und überprüft zeitgesteuerte Markov-Modelle im Zusammenhang mit Fertigungssystemen.

Hier wird insbesondere auf das bekannte Zustands-Explosions- oder Largeness-Problem eingegangen. Es wird eine gute Übersicht zu Modellen und Methoden zur numerischen Lösung großer Markov-Ketten gegeben, was auch im vorliegenden Projekt von Relevanz sein wird. Zur Identifikation und ersten Bewertung kritischer Szenarien für autonomes Fahren werden bisher in der Praxis vor allem die top-down Systems-Theoretic Process Analysis (STPA) (Abdulkhaleq et al. 2017) und die STAMP Methode (Altabbakh et al. 2014) (Bagschik et al. 2017) eingesetzt (Sabaliauskaite et al. 2018). Hier können auch vorläufige Gefährdungsanalysen (Preliminary Hazard Analyses, PH) basierend auf (standardisierten) Fehlerlisten (Hazard Lists, HL) eingeordnet werden. Markov-Analysen und Petri-Netze finden jedoch standardmäßig keine Berücksichtigung.

Das vorliegende Projekt kann folgendermaßen von EU-Projekten abgegrenzt werden , die sich mit der Sicherheit autonomen Fahrens beschäftigen: zu AutoMate mit Fokus auf Analysen zur Effizienz von Mensch-Maschine-Schnittstellen in Übergangsituationen, zu CoEXist mit Fokus auf gemischten Verkehrsszenarien (Autos mit und ohne Automation), zu ICT4CART und INFRAMIX mit Fokus auf hybride Kommunikationskanäle bzw. Schnittstellenbeschreibungen zur Infrastruktur, zu interACT mit Fokus auf der Beschreibung von menschlichen Verhaltensoptionen im Kontext autonomes Fahren sowie zu TRUSTVEHICLE, das sich mit sicherer Übernahme durch den Fahrer vor allem in kritischen Situation beschäftigt. Im Vergleich dazu strebt das vorliegende Projekt Sicherheitsbewertungen von autonomen Fahrfunktionen im Gesamtkontext an, unter Einbeziehung bestehender Informationen und Daten und gezielt generierter neuer Daten (hybrider ML/KI-unterstützter iterativer Ansatz).

Nachfolgende Abgrenzungen können zu Projekten auf nationaler Ebene vorgenommen werden. PEGASUS befasste sich mit neuen V&V-Prozessen und Methoden für den Nachweis autonomer Fahrfunktionen für den Anwendungsfall Autobahnchauffeur (SAE Level 3) (PEGASUS 2020). Es wurde eine HAZOP eingesetzt, um mögliche kritische Szenarien bzw. Top-Events zu identifizieren. Für ausgewählte Ereignisse wurden FTAs (mit Inhibit-Gate) durchgeführt, um beteiligte Subsysteme und -funktionen zu erfassen (Ericson 2005) (Bürker et al. 2019) (Böde et al. 2019). Ziel war es, Anforderungen der Normen zu erfüllen (ISO 26262 Parts 1 to 12 Ed. 2) (ISO/PAS 21448 2019), in denen solche Analysen eingebettet sind. Ziel war nicht die Weiterentwicklung der Methoden, insb. Markov- und Petrinetze wurden nicht eingesetzt (Steininger 2020).

Das 3F-Projekt mit Hauptziel sichere fahrerlose und fehlertolerante Shuttle-Fahrzeuge (Werwitzke 2020) hat sich nicht mit der Weiterentwicklung der Systemanalyseverfahren wie FMDEA, FTA, Markov- und Petri-Netzen beschäftigt. Es wurden jedoch (weiterführend) modellbasierte stochastische Petri-Netze zur Systembeschreibung und Analyse eingesetzt (Ebner et al. 2020). An einigen Stellen wurden Systemsimulationen zur redundanten Auslegung des Bordnetzes eingebunden.

V&V Methoden befassen sich mit Sicherheitsnachweisen für SAE Level 4 und 5 Funktionen am Anwendungsbeispiel Kreuzung (Plötzwich 2020a). Es wird untersucht, welche Methoden sich vorrangig auf Systemebene für Dekomposition und Komposition der Nachweisstrukturen der Sicherheitsargumentation eignen, wobei sicher FMEDA und FTA eingesetzt werden und Petri- oder Markov-Modelle lediglich eine mögliche Option darstellen (Gabas 2020). In V&V-Methoden werden von den Fraunhofer Instituten LBF und IESE zwei Systemanalysemethoden erweitert: Probabilistische FMEA auf Basis von Bayeschen Netzen (LBF) und Component Fault Trees (IESE) (Reich und Nuffer 2020). Die Zielstellung dabei ist es, die Methoden (a) zur systematischen Analyse von funktionalen Insuffizienzen zur Unterstützung der Ableitung von Systemsicherheitsanforderungen und (b) zur Verifikation der existierenden Sicherheitsmechanismen und damit zur Bewertung der Gesamtsicherheit einzusetzen. Markov-Modelle und Petri-Netze sind derzeit nicht im VVM Scope.

Set Level 4 to 5 befasst sich im Vergleich zu V&V Methoden noch deutlich weniger mit analytischen Systemanalysemethoden (Plötzwich 2020b) und damit auch nicht mit möglichen Erweiterungen. Wie auch in V&V Methoden werden Szenarien auf vielfältigen Detailebenen formal beschrieben, wobei auch Kritikalitäten definiert und gewichtet werden, um sie dann durch gekoppelte und schnittstellenoffene Simulationsmethoden mit optimaler Testparameterraumauswahl zu einer Modul- oder Systembewertung zu kommen (Mosebach 2020). Schwerpunkt sind SAE Level 4 und 5 Funktionen für den Stadtverkehr (Steinle und Menzel 2020).

KI-Absicherung entwickelt eine möglichst standardisierbare Prozesskette mit offenen Schnittstellen zur Erzeugung hochwertiger und reproduzierbarer synthetischer Trainings- und Testdatensätze mit Anwendungsschwerpunkt Fußgängererkennung. Schwerpunkt sind KI-Algorithmen, 3D-Visualisierung und Animation sowie funktionale Sicherheit (Loh2020). Entsprechend steht die Weiterentwicklung von klassischen Systemanalysemethoden, um die Sicherheit von KI zu bewerten, nicht im Vordergrund. Speziell Sicherheitsanalysen der Kategorie FMEA, FTA, klassisches Markov-Modell und Petri-Netze, die die kausale Zusammenwirkung von Komponentenfehlern zur Verletzung eines Sicherheitszieles betrachten, stehen nicht im Fokus, da solche Analysen weniger gut geeignet sind, funktionale Unzulänglichkeiten (Fokus des Projektes) von neuronalen Netzwerken zu analysieren, die stattdessen KI-spezifische Absicherungsmethoden erfordern (Mock 2020). Der vorliegende Ansatz soll Schwachstellen und Nachweisbedarfe von neuronalen Netzwerken, insbesondere bei kritischen Übergängen im Gesamtzustandsraum als Bestandteil von hoch- und voll-automatisierten Fahrfunktionen, aufzeigen. Es wird jedoch nicht beansprucht eine Quantifizierung der Kritikalität vorzunehmen. Dies hat im Rahmen von XiL, ViL oder Tests zu erfolgen, sofern es nicht bereits mit vorhandenen Daten geleistet werden kann, z.B. aus Flottendaten oder Daten der Prüforganisationen.

KIsSME untersucht, wie im Fahrzeug und falls erforderlich offboard mit gestreamten Daten relevante und kritische Szenarien erkannt werden können, um für neue Entwicklungen das Training von autonomen Fahrfunktion zu verbessern. Der Schwerpunkt liegt daher nicht auf der Bewertung der Sicherheit von autonomen Fahrfunktionen, sondern in der Bereitstellung von umfangreichen und zielgerichteten Datensätzen, z.B. fehlende Daten für bekannte kritische Szenarien oder bisher noch nicht bekannte kritische Szenarien. Dagegen nutzt das vorliegende Projekt nicht nur Flottendaten, sondern durch die Gesamtsicherheitssimulation bestehend aus ViL Simulation und Laborversuchen, gesteuert viele andere Datenquellen, u.a. auch Expertendaten, historische Daten, gezielt generierte simulative Daten für Subsysteme (XiL), Gesamtfahrzeugdaten (ViL und Vehicle tests), um die Sicherheit von vorgegebenen autonomen Fahrfunktionen bzw. konkreten Fahrzeugen zu bewerten.

Die BMWI-Projekte @City und IMAGinE fokussieren im Vergleich zum vorliegenden Vorhaben auf die Entwicklung neuer Fahrzeugtechnologien.

1.5 Zusammenarbeit mit anderen Stellen

1.5.1 Zusammenarbeit mit anderen Projekten

Durch die parallele Teilnahme der TH Augsburg und der dSPACE GmbH an den Projekten RDV und Nemobil konnten die Erkenntnisse beider Projekte in den jeweils anderen Projekten berücksichtigt werden. Auf diese Weise konnten Synergien genutzt und Doppelaufwände vermieden werden. Weiter ist ein Austausch mit dem AVEAS Projekt zum Thema kritische Testszenarien erfolgt.

1.5.2 Zusammenarbeit mit anderen Firmen/Einrichtungen

dSPACE und RA Consulting sind Mitglied in der ASAM (Association for Standardization of Automation and Measuring Systems), bis Ende 2024 war auch LiangDao Mitglied. ASAM ist eine Organisation, die die Standardisierung von Werkzeugketten in der Automobilentwicklung und -prüfung fördert. ASAM besitzt eine globale Vernetzung und aktuell eine bedeutende Position bei der Standardisierung im ADAS-Umfeld. Durch die Liaison von ASAM mit ISO und SAE wird die inhaltliche Abstimmung und Koordination der unterschiedlichen internationalen Standardisierungsinitiativen zwischen diesen Organisationen angestrebt und gefördert. Über die Mitgliedschaft bestand die Möglichkeit, Erkenntnisse aus dem RDV-Projekt in das Standardisierungsgremium einzubringen. Die Zusammenarbeit mit dem ADAC Testzentrum Mobilität in Penzing ermöglichte wertvolle Praxiserfahrungen und trug wesentlich zur erfolgreichen Durchführung der Testfahrten bei.

In Bezug auf das AP 11 wurde die Entwicklung der “Organic Computing”-Technologie in das RDV AD Referenzsystem eingebaut und in einer Systemimplementierung erstmals mit entsprechenden HW-& SW-Komponenten in einem Echtzeitsystem in prototypischer Ausprägung umgesetzt. Die Basistechnologie des “Organic Computings” zur automatischen Fehlerbehebung stammt dabei aus dem SafeAutoDoc-Projekt.

Für die Recherche zu GAIA-X wurde sich nicht nur im Konsortium ausgetauscht (LiangDao und RAC), LiangDao hatte außerdem mehrere Treffen mit Mobility Data Space (extern). Letzteres ist eine Plattform für den Datenaustausch, gefördert vom Bundesministerium für Digitales und Verkehr, und ist ein Leuchtturm-Projekt der europäischen GAIA-X Initiative. Die Erkenntnisse flossen in die Konzeption der Lösung des Teilvorhabens ein.

2 EINGEHENDE DARSTELLUNG

2.1 VERWENDUNG DER ZUWENDUNG UND ERZIELTES ERGEBNIS

Entsprechend der dargestellten Zielsetzungen in Abschnitt 1.1 gibt die folgende Tabelle 1 eine detailliertere Übersicht über Schlüsselindikatoren für das *G*esamtprojekt (Key Performance Indikators, KPIs), mit denen der Erfolg bemessen werden soll. Die Tabelle listet die KPI-Beschreibung mitsamt der Ausgangslage vor Projektbeginn, der Zielsetzung für das Projektende und das erreichte Level an eben diesem auf. Die Bewertung erfolgt mit Hilfe von Technologiereifegradabschätzungen (*technology readiness levels*, TRLs), in der jede der neun Stufen (TRL 1–9) durch eine spezifische Definition durch die EU charakterisiert ist, siehe Tabelle 2.

KPI-No.	Beschreibung KPI	TRL bei Projektbeginn	TRL geplant	TRL nach Projektende
1	Demonstration **Gesamtzustandsmodellierung** (Fahrzeug, Straßen- und Manöversituation, Wetterbedingungen, weitere Faktoren) als Erweiterung bisheriger Szenariomodelle aus Standards. Insb. aufzeigen, dass Zustandsexplosion durch Skalierung und Domänenwissen kontrolliert werden kann, ausreichend für eine Gesamtsicherheitsbestimmung und Nachweisbedarfsbestimmung.	2 - 3	6 - 7	6-8
2	(Meta) **Übergangsmodellierung** kann Fehlerarten autonomer Fahrfunktionen (ggf. abstrakt) modellieren und quantifizieren einschl. Unsicherheiten, insb. aufgrund von SW. Bekannte Fehlerarten und -modi werden abgedeckt.	3 - 9	6 - 8	6-7
3	Expertenwissen und Datenbankbestände von Prüforganisationen können in der Gesamtzustands- und Übergangsmodellierung berücksichtigt werden. Gängige Daten- und Informationsquellen werden abgedeckt. (**Expertenquantifizierung**).	3 - 6	5 - 7	5
3a	**Parametrisierung Übergangsmodelle durch XiL-Tests**. Nachweisbedarf kann gezielt durch XiL-Tests geschlossen werden.	3 - 6	5 - 7	6
3b	**Parametrisierung Übergangsmodelle durch ViL und Labor-Tests einschl. Systememulation.** Nachweisbedarf kann gezielt durch ViL/Labor-Tests geschlossen werden.	3 - 6	5 - 7	6
3c	**Parametrisierung Übergangsmodelle durch Fahrzeugtests.** Nachweisbedarf kann gezielt durch Fahrzeugtests geschlossen werden.	3 - 6	5 - 7	6
4	Methode kann in einer GAIA-X und DGSV-konformen Cloud-Lösung umgesetzt werden (**GAIA-X und DGSV-konformes Datenmanagement**).	2	6	6 (LiangDao)

5	**High-Performance Datenmanagement und -analyse** für im Fahrzeug gewonnene Daten: Für die Verfeinerung von Gesamtzustands- und Übergangsmodellen erforderlichen Daten können aus dem Fahrzeug auch gezielt durch Tests gesammelt werden, u.a. aufgrund ausreichendem Abdeckungsgrad (> 95%), Prioritätstreue (> 90% für Prio. 1), Verfügbarkeit (>95%), Datenübertragungsrate, Latenzzeit (<1 sek).	3 - 4	6 - 7	6 (LiangDao)
6	**Gezielte Datenerhebung durch Prüforganisationen** können fehlende Daten zur Bewertung der Sicherheit autonomer Fahrfunktionen in Prüfsituationen modell- und simulationsunterstützt gezielt erheben.	1 - 3	5 - 6	4
7	Die Gesamtsicherheitsmodellierung erlaubt operationalisierbare (umsetzbare) Aussagen zu fehlenden Nachweisen (**Modell- und simulationsbasierte Sicherheits-Nachweisbedarfsbestimmung**), die ausreichen für das Design von (ggf. sehr umfangreichen) XiL-Tests, ViL-Tests, gezielte Fahrzeugtests (auf Testgeländen und im Normalverkehr) sowie die gezielte Auswertung von Flottendaten.	2- 3	6 - 7	5-6
8	**Verbesserung Sicherheits-Nachweiseffizienz**: Die Nachweise selbst sind effizienter, da sie präzise und operationalisierbar spezifiziert werden und auch Zwischenergebnisse bereits zur Verfeinerung des Gesamtsicherheitsmodells verwendet werden können.	1 - 2	5 - 6	6
9	**Verbesserung Kontrolle Zustandsraumexplosion**: Der Ansatz macht die Zustandsexplosion durch kontrollierte Abstraktion und Berücksichtigung bereits verfügbarer Daten einschl. Unsicherheiten handhabbarer, wodurch eine größere Menge unsicherer Zustände identifiziert werden können und die Menge der Unbekannten im Sinne des SOTIF-Standards reduziert wird.	2	5	6-7
10	**Früherkennung von Fehlern in Systemupdates:** Demonstration, dass Fehler in Systemupdates (Softwareupdates) auf Fahrzeugebene (auch redundant) frühzeitig erkannt werden.	2- 3	6 - 7	6

Tabelle 1: Übersicht der KPIs zur Bewertung des Erfolgs des Projektes.

Die KPIs wurden teilweise getrennt von verschiedenen Partnern in ihren jeweiligen Arbeitspaketen bearbeitet. Die für die Arbeiten von LiangDao im Teilvorhaben relevanten KPIs sind #4 (GAIA-X und DGSV-konformes Datenmanagement) und #5 (High Performance Datenmanagement und -analyse für im Fahrzeug gewonnene Daten), wobei letzterer auch von TTTech bearbeitet wurde. Die jeweiligen Anforderungen für die Erfüllung der KPIs können sich je Partner leicht unterscheiden.

Stufe	Definition
1	Beobachtung des Funktionsprinzips
2	Beschreibung von Anwendungsszenarien
3	Nachweis der Funktionsfähigkeit des Konzepts
4	Versuchsaufbau im Labor
5	Versuchsaufbau und Überprüfung in relevanter Einsatzumgebung
6	Demonstration in relevanter Einsatzumgebung
7	Demonstration im (realen) Einsatz
8	Nachweis der Funktionstüchtigkeit des qualifizierten Systems
9	Nachweis des erfolgreichen Einsatzes des qualifizierten Systems

Tabelle 2: Übersicht technologiacl readiness levels (TRLs)

Es folgt die Beschreibung der relevanten Arbeiten von LiangDao für das Teilvorhaben. Die relevanten Arbeitspakete waren AP5 und AP1.3. Die Darstellung erfolgt gemeinsam.

2.1.1 Industrial Cloud-Datenmanagement und -Analyseservices (LiangDao)

Ziel war die Entwicklung eines skalierbaren, Cloud-basierten Datenmanagement- und Analyseservices für relevante Fahrzeugdaten. Diese sollten in Echtzeit empfangen, gespeichert, verarbeitet, visualisiert und zum Download bereitgestellt werden.

Zu Beginn wurden gemeinsam mit den Projektpartnern die relevanten Fahrzeugdaten identifiziert und die daraus resultierenden Anforderungen an Datenübertragung, Volumen und Schnittstellen definiert. Ebenso erfolgte die Abstimmung zu Anforderungen an die Analyseservices und das Frontend-Design, wobei eine hohe Skalierbarkeit der Lösung ein zentrales Entwicklungsziel blieb (AP5.1, AP5.5 und AP1.3).

Letztendlich wurde sich mit den Partnern auf einen zu übermittelnden Datensatz geeinigt, der neben CAN-Daten auch Objektlisten aus OnBoard verarbeiteten LiDAR-Sensordaten enthält. Die LiDAR-Rohdaten werden im Fahrzeug durch einen KI-basierten Perzeptionsalgorithmus analysiert, der Objekte in der Umgebung (z. B. Pkw, Lkw, Busse, Fußgänger) erkennt, klassifiziert und mit weiteren Attributen wie Zeitstempel, Position und Geschwindigkeit anreichert.

Die Konformität der Lösung mit europäischen Datenschutzstandards wurde in AP5.2 geprüft und sichergestellt. Da die übertragenen Objektlisten keine personenbezogenen Daten oder identifizierbare Merkmale wie Kennzeichen enthalten, sind die Datensätze intrinsisch DSGVO-konform. Dies gilt ebenso bei der Umsetzung einer Übertragung von LiDAR-Rohdaten (Punktwolken). Die Auflösung von Punktwolken ist zu gering, um Gesichter zu identifizieren oder KFZ-Kennzeichen auszulesen, siehe Abbildung 22 für ein Beispiel aus LiDAR-Punktwolken und überlagerten Bounding-Boxen aus der Objektliste.

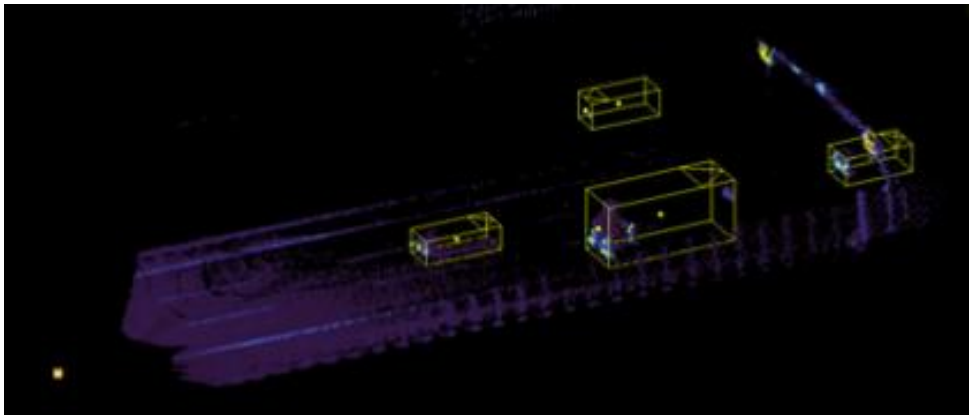

Abbildung 2: LiDAR-Punktwolke, überlagert mit Bounding-Boxen aus einer Objektliste, aufgenommen während einer Autobahnfahrt.

Als Cloud-Anbieter wurde nach Evaluierung verschiedener Optionen die Open Telekom Cloud (Deutsche Telekom) gewählt. Diese ermöglicht die Wahl des Rechenzentrumsstandorts (im Fall der LiangDao-Cloud: Biere, Sachsen-Anhalt), arbeitet selbst DSGVO konform und Datensouveränität ist im Sinne der GAIA-X-Initiative gegeben. Dazu ist sie TISAX-zertifiziert, ein Sicherheitsstandard für Informationsverarbeitung in der Automobilindustrie. Die Datenausgabe erfolgt zusätzlich ASAM OpenX-konform, womit eine Weiterverwendung auch außerhalb des Konsortiums möglich ist.

Zur Einbindung von GAIA-X-Prinzipien fand ein intensiver Austausch mit Partnern wie RA Consulting (projektintern) und Mobility Data Space (extern) statt. Die Erkenntnisse flossen in die Konzeption der Lösung ein, wobei eine Live-Datenübertragung in Echtzeit derzeit noch nicht umsetzbar ist.

Nach dem Austausch mit den Partnern und der nötigen Recherche wurde ein Konzept für die zu entwickelnde Lösung erarbeitet und in den Arbeitspaketen 5.3, 5.4 und 1.3 umgesetzt.

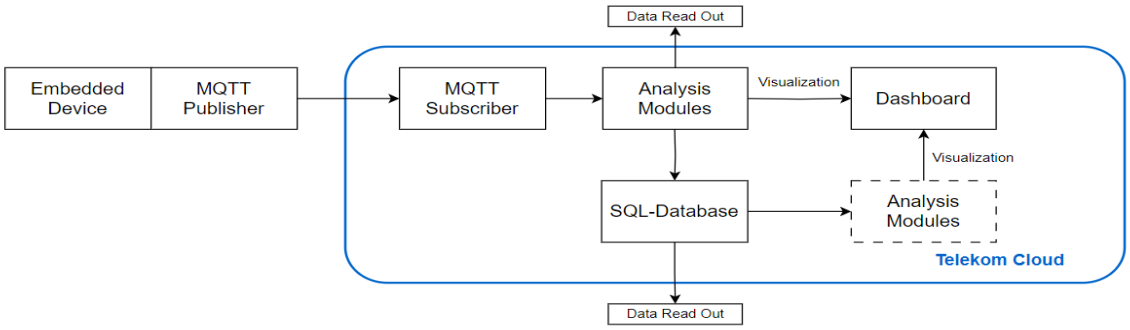

Abbildung:3 3 Schema der erarbeiteten Lösung für die Cloud-basierten Datenmanagement- und Analyse-Services.

Die erarbeitete Lösung, siehe Schema in Abbildung 3, basiert auf einer Cloud-Plattform, die über eine verschlüsselte Mobilfunkanbindung mittels MQTT-Protokoll Daten empfängt. Die Daten werden analysiert, in einer SQL-Datenbank gespeichert und können sowohl als Livestream als auch als historische Datensätze visualisiert oder heruntergeladen werden.

Zwei Datenströme sind prinzipiell übertragbar:

1. Objektlisten aus OnBoard-verarbeiteten LiDAR-Daten (inkl. CAN- und GNSS-Informationen),

2. LiDAR-Rohdaten.

Da Rohdaten jedoch sehr große Datenmengen erzeugen - 100 Mbit/s je Sensor und mehr, abhängig von der Auflösung - und die Skalierbarkeit der Cloud stark einschränken würden, konzentriert sich die Lösung auf Objektlisten (≈ 1 Mbit/s), größtenteils unabhängig von der Anzahl der Sensoren ihrer Auflösung und Reichweite - , die eine praxisgerechte Datenübertragung und Analyse ermöglichen.

Die Rechenanforderungen der Cloud bleiben moderat, da die aufwändige LiDAR-Verarbeitung bereits im Fahrzeug erfolgt. In der Cloud werden hauptsächlich Objektlisten eingelesen, ausgewertet und über ein Dashboard tabellarisch oder grafisch dargestellt.

Bei der Evaluation der Anforderungen stellte sich heraus, dass die Partner einerseits eine Analyse von Live-Daten benötigen, aber andererseits auch Zustandsveränderungen über mehrere Stunden oder Tage nachgehen wollen, wozu eine Datenbank mit historischen Daten benötigt wird. Während für die Auswertung von Live-Daten die Datenrate der Objektlisten kein Problem darstellt, wächst die Datenmenge für die Datenbank schnell auf ein Volumen an, dass die Anmietung größerer Mengen an Cloudspeicher erfordern und unwirtschaftlich machen würde.

Zur Speicherung historischer Daten wurde daher ein Konzept zur Reduktion des Datenvolumens entwickelt, das je nach Use Case spezifisch konfiguriert werden kann. Dadurch bleibt die Lösung wirtschaftlich skalierbar – selbst bei hohen Fahrzeugzahlen.

Für den weiteren Verlauf konzentrierte sich LiangDao in Absprache mit den Partnern auf die Erfassung und Zählung erkannter Objekte. Der Datenstrom wird entsprechend gefiltert und in einer SQL-Datenbank gespeichert.

Zur Erprobung und Validierung wurden mehrere Experimente durchgeführt. Die Experimente erfolgten sowohl mit zuvor aufgezeichneten Datenpaketen als auch mit Live-Übertragungen aus Versuchsfahrzeugen. Letztere zeigten wieder, dass nicht von einer durchgehenden Mobilfunkanbindung auf deutschen Straßen ausgegangen werden kann. Diesem Umstand wurde im weiteren Verlauf der Entwicklung Rechnung getragen, indem nichtversendbare Daten zunächst im Fahrzeug zwischengespeichert und später bei einer wieder verfügbaren Verbindung parallel zum aktuellen Datenstrom versendet wurden. Dabei wurden die Live-Daten priorisiert. Die historischen Daten wurden zeitlich korrekt in der Cloud-SQL-Datenbank abgelegt.

In weiteren Tests wurde die parallele Verarbeitung und Darstellung zweier Datenströme erprobt, siehe Abbildung 4. Dabei werden sowohl Live-Daten (oben) als auch aggregierte Session-Daten (unten) visualisiert. Eine weitere Seite erlaubt einen Blick auf die gesamte Datenbank und den Download der Einträge als CSV-Datei.

Abbildung 4:4 Dashboard mit Zählung der erfassten Objekte in zwei Datenströmen (links und rechts). Gezeigt wird sowohl die Live erfasste Anzahl an jeweiligen Objekten (oben), als auch die Werte für die gesamte Session (Mitten, unten).

2.1.2 Arbeiten in Use Cases

Zum Austausch und zur Förderung der gemeinsamen Arbeiten wurden im Konsortium fünf Use Cases definiert. Jeder Use Case adressiert spezifische Anforderungen und Fragestellungen innerhalb des Projekts. Die Use Cases und die damit zu bearbeitenden Fragestellungen sind in der **Fehler! Verweisquelle konnte nicht gefunden werden.**5 dargestellt. LiangDao war zentraler Bestandteil von Use Case 1 (Qualitätsbewertung) und unterstützte in Use Case 3 (Absicherungs-Blueprint). Die Arbeiten in allen Use Cases sind detailliert im gemeinsamen Schlussbericht des Konsortiums beschrieben. Hier wird sich auf die Arbeiten von LiangDao fokussiert.

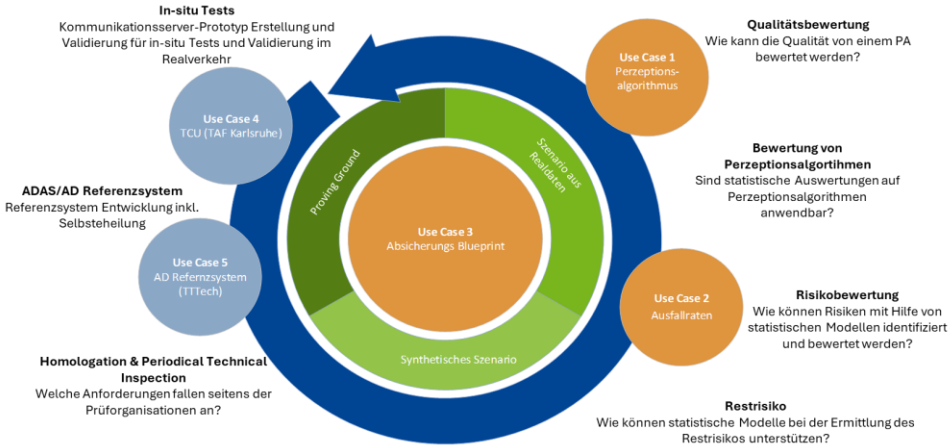

Abbildung 5: Überblick der im Projekt bearbeiteten Use Cases.

2.1.2.1 Use Case 1

Im Use Case 1 bestand das Ziel darin, eine fundierte Aussage zur Bewertung von Perzeptionsalgorithmen zu treffen. Dabei standen zwei zentrale Fragestellungen im Fokus:

1. Wie kann die Qualität von einem Perzeptionsalgorithmus bewertet werden?

2. Sind statistische Auswertungen auf Perzeptionsalgorithmen anwendbar?

Zur Bearbeitung dieser Fragen wurde eine Test-Pipeline erstellt (siehe Abbildung 6) mit den Beiträgen der einzelnen Partner.

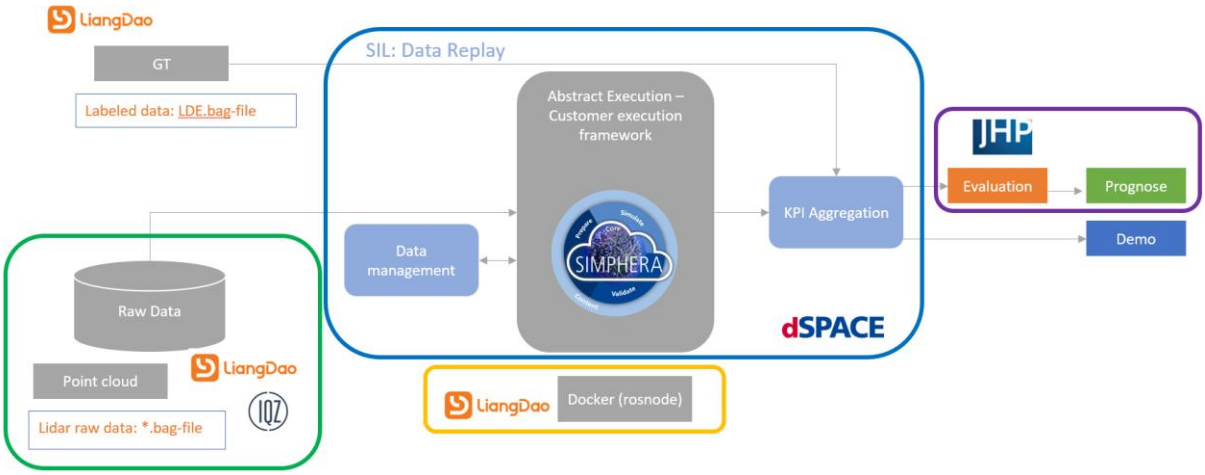

Abbildung 6: Schema der Verarbeitungspipeline Use Case 1.

Ausgangsdaten (LiDAR-Rohdaten) werden in einer Software-in-the-Loop-Umgebung mit mittels Perzeptionsalgorithmen verschiedener Qualität verarbeitet. Verschiedene Qualität bedeutet, die KI-Algorithmen wurden mit einer unterschiedlichen Menge an Daten trainiert. Die resultierenden Objektlisten werden mit Ground-Truth-Daten abgeglichen und anhand definierter KPIs, wie *Precision* und *Recall* kleinteilig evaluiert. Die Evaluationsergebnisse werden anschließend einer statistischen Analyse unterzogen, um abschätzen zu können, ob ein bestimmter KI-Algorithmus bereits *austrainiert* ist, also durch Training nicht mehr verbessert werden kann - oder nicht. Dies kann etwa die Ressourcenplanung in der Algorithmen-Entwicklung verbessern bzw. effizienter gestalten (muss ein Algorithmus weiter trainiert werden, müssen weitere Trainingsdaten eingefahren werden, oder ist eine Anpassung des Deep Learning Netzwerkes nötig).

Neben den ursprünglichen Ausgangsdaten werden diese auch manipuliert eingespeist, um die Auswirkungen von bestimmten Störungen auf das Ergebnis zu bestimmen, etwa externe (Wetter) oder interne (Defekte) Störungen.

LiangDao trug drei speziell für die Projektanforderungen trainierte Perzeptionsalgorithmen bei. Diese wurden jeweils mit Sensordaten aus den Umgebungen *Autobahn* und *Stadtverkehr* trainiert – in drei unterschiedlichen Trainingsumfängen: 2 Prozent, 60 Prozent und 100 Prozent der verfügbaren maximalen Trainingsdatenmenge.

Ziel war es, drei Reifegrade des Algorithmus zu erzeugen – einen unausgereiften, einen gering entwickelten und einen relativ ausgereiften Algorithmus –, um die Leistungsunterschiede systematisch bewerten zu können. Die Datensätze der kleineren Trainingsumfänge bildeten dabei jeweils eine Teilmenge der größeren, sodass eine direkte Vergleichbarkeit der Modelle gewährleistet war.

Für die Evaluierung wurde zusätzlich ein Referenzdatensatz mit fünf verschiedenen Szenarien bereitgestellt, der Ground-Truth-Daten zur objektiven Bewertung enthielt. Die Daten wurden auch IQZ zur Verfügung gestellt für die Generierung der manipulierten Daten. In enger Abstimmung mit den Projektpartnern erfolgte die iterative Implementierung der Algorithmen in das dSPACE-Testframework.

Parallel wurden gemeinsam die Methoden zur Auswertung und Interpretation der Ergebnisse spezifiziert und abgestimmt.

Anhand der gesammelten Daten konnte JHP zeigen, dass die Streuungen der Maße *Precision* und *Recall* normalverteilt sind, woraus auswertungstechnisch ein großer Vorteil entsteht. Beide Maße wurden mit steigendem Training besser, wobei sie nicht vollständig miteinander korrelieren. Während es bei einem der Maße schon zu Sättigungserscheinungen kommt, kann das andere noch stark von weiterem Training profitieren. Es konnte im Weiteren gezeigt werden, dass anhand der statistischen Analysen Ursachen für auffällige Werte gefunden werden können. Anhand der Ergebnisse lässt sich aussagen, dass statistische Methoden im Bereich der KI-Perzeptionsalgorithmus-Entwicklung sowohl der Reifegradbewertung als auch als Entwicklungswerkzeug dienen können. Für weitere Details der Partnerbeiträge siehe den gemeinsamen Schlussbericht.

2.1.2.2 Use Case 3 Absicherungs-Blueprint

Use Case 3 beschäftigte sich mit der Validierung von Vehicle-Dynamics-Modellen, wozu u.a. auf dem Testgelände in Penzing Manöver nach ISO 7401 abgefahren und Daten wie Lenkwinkel, Geschwindigkeit, u.a. geloggt wurden. Die Fahrten erfolgten durch die TH Augsburg mit einem von INYO bereitgestellten Fahrzeug. Für dieses wurde von LiangDao ein LiDAR-Sensor mitsamt passendem Perzeptionsalgorithmus als Docker zur Verfügung gestellt, sowie das Personal zu Fragen des Umgangs mit Hardware und Software technisch beraten. Allerdings erfolgte die Bereitstellung des Fahrzeugs so spät, dass die Fahrten gegenüber der ursprünglichen Planung nur mit einem reduzierten Satz an Sensoren durchgeführt werden konnten. Für die Implementierung der von LiangDao bereitgestellten Komponenten blieb leider keine Zeit.

2.1.3 Zusammenfassung der wissenschaftlich-technischen Ergebnisse

Die Lösung für Datenmanagement und Analyseservices wurde erfolgreich in einer Cloud bereitgestellt, getestet und validiert. Die Verbindung zu Fahrzeugen im Feld verlief erfolgreich, die übertragenen Daten wurden in nahezu Echtzeit gespeichert, verarbeitet und über ein Dashboard und eine Download-Funktion zur Verfügung gestellt. Die Art der Daten (Inhalt, Format, verwendete Einheiten, Volumen, etc.) wurde zuvor mit den Partnern im Konsortium definiert, ebenso die zu verwendenden Schnittstellen. Auch die Analyse erfolgte entlang der zuvor mit den Partnern erarbeiteten Anforderungen. Die Ergebnisse wurden ihnen präsentiert und von ihnen abgesegnet. Die erarbeitete Lösung ist prinzipiell auch auf lokalen Servern lauffähig, d.h. sie kann zum Beispiel ebenso für Datenmanagement und Analyse auf Testfeldern mit nicht öffentlichem Netzwerk eingesetzt werden.

Trotz der kurzen Zeit im Vorhaben konnte LiangDao alle im Teilvorhaben gesteckten Ziele erreichen. In dem für das Teilvorhaben relevanten KPIs #4 (GAIA-X und DGSV-konformes Datenmanagement) und #5 (High Performance Datenmanagement und -analyse für im Fahrzeug gewonnene Daten), sollte ein TRL-Level von mindestens 6 angestrebt werden. Wobei TRL 6 die Demonstration der Technologie in einer relevanten Umgebung voraussetzt und TRL 7 den Test eines Prototypen in *real life use* bedeutet. Nach Evaluation der Ergebnisse hat LiangDao für die Lösung in beiden KPIs TRL 6 erreicht: Die Testfahrzeuge sendeten relevante Daten von der Straße, die in der Cloud empfangen wurden. Dort wurden sie echtzeitnah verarbeitet, gespeichert und visualisiert. Die Daten wurden 1 zu 1 übertragen. Bei Verlust der Verbindung wurden sie OnBoard zwischengespeichert und bei wiederhergestellter Verbindung parallel zu

aktuellen Daten versendet. Die Methode ist DSGVO-konform und so weit wie möglich kompatibel mit GAIA-X. Allerdings ist mittels GAIA-X noch keine Live-Übertragung von Daten möglich.

Neben den Arbeiten im AP engagierte sich LiangDao in den konsortiums-übergreifenden Use Cases, besonders in Use Case 1, und lieferte Daten, eigens trainierte Perzeptionsalgorithmen und weiteres Know-how für die Umsetzung.

2.2 Wichtigste Positionen des zahlenmäßigen Nachweises

Zu den wesentlichen Kostenfaktoren bei der LiangDao GmbH zählten die Personalkosten des wissenschaftlich-technischen Personals. Dieses zeichnete sich verantwortlich für die Entwicklung der Industrial Cloud-Datenmanagement und -Analyseservices, für den Austausch und die Diskussionen mit den Partnern, insbesondere in den Use Cases sowie Training und Bereitstellung der Perzeptionsalgorithmen und der Datensätze für die Durchführung von Use Case 1. Reisemittel wurden nur für die Besuche der Konsortialtreffen und der Abschlussveranstaltung benötigt. Für eine Übersicht siehe Tabelle 3.

Kostenart	Kosten
Personalkosten	640.666,97 €
Reisekosten	260,32 €
Gesamte Selbstkosten des Vorhabens	640.927,29 €

Tabelle 3: Übersicht zum zahlenmäßigen Nachweis

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

2.3 Notwendigkeit und Angemessenheit der Arbeit

Das Projektziel sowie die damit verbundenen Aufgaben waren 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. Lediglich die für Use Case 3 bereitgestellten Komponenten konnten aufgrund von Zeitmangel von den Partnern nicht mehr implementiert werden. Die Bereitstellung nahm jedoch kaum Zeit in Anspruch (weniger als einen halben Arbeitstag) und ist daher zu vernachlässigen. Die durchgeführten Arbeiten waren zu jeder Zeit für die Erfüllung der Aufgaben und der eigentlichen Ziele nicht nur notwendig, sondern auch angemessen. Ohne die bereitgestellte Förderung durch das BMWE, sowie ohne das Netzwerk des Konsortiums wären weder die Arbeiten in den APs an sich noch die gemeinsamen Use Cases möglich gewesen.

2.4 Nutzen und Verwertbarkeit

Die von LiangDao entwickelte Cloud-Lösung ermöglicht eine skalierbare und DSGVO-konforme Speicherung, Verarbeitung und Analyse relevanter Fahrzeugdaten. Durch standardisierte Schnittstellen bzw. Formate (ASAM OpenX) und hohe Datensicherheit (TISAX, europäische Cloud) kann die Lösung flexibel in bestehende Entwicklungsumgebungen integriert werden.

Die Ergebnisse bieten eine belastbare Grundlage für zukünftige Datenaustausch- und Validierungsplattformen im Kontext des autonomen Fahrens und von GAIA-X. Das sich in Arbeit

befindliche marktfähige Produkt kann einen großen Beitrag zu der forstschreitenden Vernetzung von Fahrzeugen leisten, zwischen Fahrzeugen und Entwicklerteams/Herstellern, Prüforganisationen oder Infrastrukturbetreibern. Darüber hinaus lässt sich die entwickelte Lösung leicht für andere Zielsetzungen optimieren, etwa für die Bereitstellung von Smart-City-Lösungen zur Verkehrsanalyse.

Für LiangDao ist die hier vorgestellte Lösung außerdem der Grundstein für die Weiterentwicklung seiner Produkte sowohl im Bereich Automotive als auch im Bereich Smart-City. Sie vervollständigt in beiden Geschäftsbereichen die Verarbeitungskette: von der Aufnahme der Rohdaten und der optionalen Verarbeitung vor Ort (Fahrzeug, Infrastruktur-Roadside-Unit) zu Objektlisten, zum Versenden an eine zentrale Plattform mit automatisierter Weiterverarbeitung und Datenspeicherung, bis zur Verteilung bzw. Bereitstellung an Kunden/Endsysteme sowie zur Datenvisualisierung.

2.5 Bekannt gewordener Fortschritt

Im Rahmen der Recherche wurden mehrere Cloud-basierte Lösungen identifiziert, die allgemein das Sammeln, Speichern und Auswerten von Fahrzeugdaten aus dem deutschen und internationalen Automobilsektor ermöglichen. Deutsche Anbieter wie Bosch (u. a. „Automotive Data Transformer“ und „IoT Insights“) bieten Plattformen für die Erfassung und Analyse von Mess- und Diagnosedaten. Trendfire Telematik liefert eine browserbasierte Flottenlösung mit Servern in Deutschland, während Hella mit „macsLive“ cloudgestützte Ferndiagnosen in Echtzeit ermöglicht. ETAS, eine Bosch-Tochter, stellt mit ihrem cloudbasierten „Vehicle Analytics Framework“ speziell für Entwicklungs- und Testfahrzeuge eine skalierbare Analyseplattform bereit.

Neben diesen nationalen Angeboten existieren internationale Lösungen wie „Sonatus Collector AI“, das dynamische Datenabfragen über Trigger und Regeln unterstützt sowie AWS „IoT FleetWise“, zur Sammlung und Standardisierung von Fahrzeugdaten.

Die Lösung von LiangDao, angelegt, um für den RDV-Ansatz relevante Daten zu empfangen und entsprechend aufzubereiten, scheint jedoch mit seiner Ausrichtung ein Alleinstellungsmerkmal zu haben. LiangDao hofft, dieses Alleinstellungsmerkmal durch die weitere Zusammenarbeit mit den Partnern im Konsortium auszubauen.

2.6 Veröffentlichung der Ergebnisse

Bisherige Veröffentlichungen des Konsortiums. Für eine aktualisierte Liste siehe den später publizierten gemeinsamen Schlussbericht.

1. Horeis, T.F., et al.: A Self-Adapting Reconfiguration Process for The Failure Management of Highly Automated Vehicles. ESREL (2022)
2. Häring, I., et al.: Advanced Markov Modeling and Simulation for Safety Analysis of Autonomous Driving Functions up to SAE 5 for Development, Approval and Main Inspection. ESREL (2022)
3. Horeis, T. F., et al.: Towards Verification of Self-Healing for Autonomous Vehicles. Proceedings of the 33rd European Safety and Reliability Conference. ESREL (2023)
4. Häring, I., et al.: Overall Markov Diagram Design and Simulation Example for Scalable Safety Analysis of Autonomous Vehicles. ESREL (2023)
5. Häring, I., et al.: Dynamically Resolving and Abstracting Markov Models for System Resilience Analysis. ESREL (2023)
6. Jain, A. K., et al.: Deep Behavioral Replication of Markov Models for Autonomous Cars using Neural Networks. ESREL (2023)
7. Walz, T. P., et al.: Markov Modelling for Autonomous Vehicle Safety Assessment: Numerical Modularization to Avoid System State-Explosion. IEEE Intelligent Transportation Systems Conference (2023)
8. Richter, A., et al.: Components and Their Failure Rates in Autonomous Driving. ESREL (2023)
9. Mopuru, S. K. R.: Safety analysis of autonomous driving by Markov modeling with focus on hardware architectures. Master Thesis, Hochschule Bremerhaven (2023)
10. Sandela, N.: Safety and Reliability Analysis of Autonomous Driving using Markov Modeling and Deep Learning. Master Thesis, Otto von Guericke Universität Magdeburg (2023)
11. Dhanani, M.: Failure and Recovery Models of Autonomous Vehicles Subsystems for Markov Safety Simulation. Master Thesis, Hochschule Nordhausen (2023)
12. Häring, I., et al.: Failure and repair rates for lane detection for safety assessment of autonomous driving from CARLA simulation. ESREL (2024)
13. Häring, I., et al.: Failure rates per time for autonomous driving safety assessment from CARLA simulation. ESREL (2024)
14. Rupalla, A., et al.: Von der Telemetrie zu Teleoperation - Anforderungen und Machbarkeit. 17. Tagung „Diagnose in mechatronischen Fahrzeugsystemen (2024)
15. Rupalla, A., et al.: From Telematics to Teleoperation. AIC ASAM International Conference (2024)
16. Padariya, R.: Failure rate estimation of lane detection from CARLA Simulation for Markov Model safety assessment of autonomous driving functions. Master Thesis, Westsächsische Hochschule Zwickau (2024)
17. Jäger, P., et al.: Vom Unsichtbaren zum Messbaren. HANSER automotive 4/2025, Seite 22-25. (2025)
18. Jäger, P., et al.: Approach for a reliability proof of autonomous vehicles compared to human drivers through real-world road tests. ESREL (2025)
19. Chimbalkar, U.: Numerical and Monte Carlo Modelling of Scaling Markov Models to control State Space Explosion. Master Thesis, RWU, Hochschule Ravensburg-Weingarten (2025)
20. Nelluri, V. S.: Behaviour replication of Markov chains using Deep learning for reliability analysis of autonomous cars. Master Thesis, Albert-Ludwigs-Universität Freiburg (2025)
21. Häring, I., et al.: Scaling sparse Markov model of autonomous vehicle functions including environment, driver and traffic conditions for reliability and safety assessment. Special Issue Journal Paper Risk Analysis, eingereicht

3 LITERATURVERZEICHNIS

1. Abdulkhaleq, A., et al. : A Systematic Approach Based on STPA for Developing a Dependable Architecture for Fully Automated Driving Vehicles. In: *Procedia Engineering* 179, S. 41–51. (2017) DOI: 10.1016/j.proeng.2017.03.094.
2. Altabbakh, H. et al.: STAMP – Holistic system safety approach or just another risk model? In: *Journal of Loss Prevention in the Process Industries* 32, S. 109–119. (2014) DOI: 10.1016/j.jlp.2014.07.010.
3. Aljohani, T. M., et al.: Real-Time metadata-driven routing optimization for electric vehicle energy consumption minimization using deep reinforcement learning and Markov chain model. In: *Electric Power Systems Research* 192 (3), p. 106962. (2021) DOI: 10.1016/j.epsr.2020.106962.
4. Bagschik, G., et al.: Safety Analysis Based on Systems Theory Applied to an Unmanned Protective Vehicle. In: *Procedia Engineering* 179, S. 61–71. (2017) DOI: 10.1016/j.proeng.2017.03.096.
5. Bock, T., et al.: Validation of the Vehicle in the Loop (VIL); A milestone for the simulation of driver assistance systems. IEEE Intelligent Vehicles Symposium, S. 612–617. (2007) DOI: 10.1109/IVS.2007.4290183.
6. Bock, T., et al.: Vehicle in the Loop. In: *ATZ Automobiltech Z* 110 (1), S. 10–16. (2008) DOI: 10.1007/BF03221943.
7. Böde, E., et al.: Identifikation von Automationsrisiken hochautomatischer Fahrfunktionen in PEGASUS. In: *AAET (Hg.): Proceedings AAET Automatisiertes und vernetztes Fahren 2019*. ITS mobility e. V., S. 315–329. (2019) Online verfügbar unter https://www.pegasusprojekt.de/files/tmpl/pdf/Identifikation%20von%20Automationsrisiken%20hochautomatisierter%20Fahrfunktionen....pdf , zuletzt geprüft am 19.11.2025.
8. Bondesson, C.: Modelling of safety concepts for autonomous vehicles using semi-Markov models. Examensarbeit. Upsala Universitet, Teknisk-naturvetenskaplig fakultet UTH-enheten. (2018) Online verfügbar unter https://pdfs.semanticscholar.org/22fb/3be001a8539da6b9dea8963337eeef98eda2.pdf. , zuletzt geprüft am 19.11.2025.
9. Bürker, M. et al.: Identifikation von Automationsrisiken hochautomatischer Fahrfunktionen in PEGASUS. In: *AAET Automatisiertes und vernetztes Fahren.* ITS mobility e. V, S. 315–329. (2019)
10. Cherfi, A., et al.: Modeling automotive safety mechanisms: A Markovian approach. In: *Reliability Engineering & System Safety* 130, S. 42–49. (2014) DOI: 10.1016/j.ress.2014.04.013.
11. Ebner, Ch., et al.: Model-Based Dependability Analysis of Fail-Operational Electric Drivetrains. AIM, S. 256–263. (2020)
12. Ericson, C.: Hazard Analysis Techniques for System Safety: Wiley. (2005)
13. Fragapane, G., et al.: Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda. In: *European Journal of Operational Research* 294 (2), S. 405–426. (2021) DOI: 10.1016/j.ejor.2021.01.019.
14. Gabas, R.: Verwendung von Systemanalysemethoden im BMWi-Projekt V&V Methoden, E-Mail an Ivo Häring. (13.10.2020)
15. Gheraibia, Y., et al.: An Overview of the Approaches for Automotive Safety Integrity Levels Allocation. In: *J Fail. Anal. and Preven.* 18 (3), S. 707–720. (2018) DOI: 10.1007/s11668-018-0466-9.
16. Gomes, A., et al.: Constructive model-based analysis for safety assessment. In: *Int J Softw Tools Technol Transfer* 14 (6), S. 673–702. (2012) DOI: 10.1007/s10009-012-0238-x.

17. Heinrich, J., et al.: State-based safety and availability analysis of automated driving functions using Monte Carlo simulation: CRC Press, S. 1975–1982. (2017)
18. Huang, W., et al.: Autonomous vehicles testing methods review. ITSC, S. 163–168. (2016), DOI: 10.1109/ITSC.2016.7795548.
19. Kaalen, S., et al.: Semi-Markov processes for calculating the safety of autonomous vehicles. Degree project in mathematics, second cycle. Stockholm (2019)
20. Kaalen, S., et al.: Tool-Supported Dependability Analysis of Semi-Markov Processes with Application to Autonomous Driving. ICSRS, pp. 126–135. (2019)
21. Loh, S. et al.: KI-Absicherung: Wie autonomes Fahren sicherer wird. Industriekonsortium entwickelt im Rahmen der VDA-Leitinitiative »Autonomes und vernetztes Fahren« Lösungen zur Absicherung von KI-Funktionsmodulen. Fraunhofer IAIS. (2020) Online verfügbar unter https://www.iais.fraunhofer.de/de/presse/presseinformationen/presseinformationen-archiv/presseinformationen-2020/presseinformation-200526.html, zuletzt geprüft am 19.11.2025.
22. Macher, G., et al.: Threat and Risk Assessment Methodologies in the Automotive Domain. In: *Procedia Computer Science* 83, S. 1288–1294. (2016) DOI: 10.1016/j.procs.2016.04.268.
23. Mock, M.: Verwendung von analytischen Systemanalysemethoden im BMWI-Projekt KI-Absicherung, E-Mail an Ivo Häring. (22.10.2020)
24. Mosebach, H.: Verwendung von analytischen Systemananlysemethoden im BMWi-Projekt Set Level 4 to 5, E-mail an Ivo Häring. (13.10.2020)
25. Nyberg, M.: Safety analysis of autonomous driving using semi-Markov processes: Taylor and Francis Group, S. 781–788. (2018) Online verfügbar unter https://doi.org/10.1201/9781351174664, https://www.taylorfrancis.com/books/e/9781351174664, zuletzt geprüft am 19.11.2025.
26. PEGASUS: Projekt zur Etablierung von generell akzeptierten Gütekriterien, Werkzeugen und Methoden sowie Szenarien und Situationen zur Freigabe hochautomatisierter Fahrfunktionen. Schlussbericht für das BMWi Gesamtprojekt PEGASUS. (2020) Online verfügbar unter https://www.pegasusprojekt.de/files/tmpl/pdf/PEGASUS_Abschlussbericht_Gesamtprojekt.PDF, zuletzt geprüft am 19.11.2025.
27. Plötzwich, F.: (2020a): Projekt arbeitet an rechtssicherer Freigabe autonomer Autos. Projektstart V&V Methoden. Hg. v. SpringerProfessional. (2020) Online verfügbar unter https://www.springerprofessional.de/automatisiertes-fahren/funktionale-sicherheit/projekt-arbeitet-an-rechtssicherer-freigabe-autonomer-autos/17042454, zuletzt geprüft am 19.11.2025.
28. Plötzwich, F. (2020b): Verwendung von analytischen Systemanalysemethoden im BMWi-Projekt V&V Methoden, E-Mail an Ivo Häring. (09.10.2020)
29. Reich, J., et al: Verwendung von Systemanalysemethoden im Projekt BMWI-V&V Methoden, E-Mail an Ivo Häring. (16.10.2020)
30. ISO 26262 Parts 1 to 12 Ed. 2, 2018-12: Road vehicles - Functional safety
31. ISO/PAS 21448 2019, 2019-01: Road vehicles — Safety of the intended functionality, SOTIF.
32. Papadopoulos, Ch., et al.: A classification and review of timed Markov models of manufacturing systems. In: *Computers & Industrial Engineering* 128 (12), pp. 219–244. (2019)
33. DOI: 10.1016/j.cie.2018.12.019.
34. Rosique, F., et al.: A Systematic Review of Perception System and Simulators for Autonomous Vehicles Research. In: *Sensors (Basel, Switzerland)* 19 (3). (2019) DOI: 10.3390/s19030648.
35. Sabaliauskaite, G. et al.: Integrating Autonomous Vehicle Safety and Security Analysis Using STPA Method and the Six-Step Model. In: *International Journal on Advances in Security* 11 (1&2), S.

160–169. (2018) Online verfügbar unter http://www.iariajournals.org/security/sec_v11_n12_2018_paged.pdf, zuletzt geprüft am 19.11.2025.

36. Satsrisakul, Y.:Quantitative probabilistic safety assessment of autonomous car functions with Markov models. Master Thesis. Universität Freiburg, Freiburg. INATECH. (2018)
37. Steininger, U.: Verwendung von analytischen Systemanalysemethoden im BMWi-Projekt PEGASUS aus Sicht des TÜV Süd: HA, FMEXA, FTA, Markov- und Petrinetze, Telefonat mit Ivo Häring. (10.10.2020)
38. Steinle, M., et al.: SET Level 4 to 5. (2020) Online verfügbar unter https://www.ifr.ing.tu-bs.de/de/ag-elektronische-fahrzeugsysteme/forschung/set-level-4to5/, zuletzt geprüft am 19.11.2025.
39. Talebberrouane, M. et al.: Availability analysis of safety critical systems using advanced fault tree and stochastic Petri net formalisms. In: *Journal of Loss Prevention in the Process Industries* 44, S. 193–203. (2016) DOI: 10.1016/j.jlp.2016.09.007.
40. Werwitzke, C.: Bosch: Wie autonome Shuttles Störungen selbst bewältigen. Hg. v. Branchendienst für Elektromobilität electrive.net. (2020) Online verfügbar unter https://www.electrive.net/2020/04/05/bosch-wie-autonome-shuttles-stoerungen-selbst-bewaeltigen/, zuletzt geprüft am 19.11.2025.
41. Winkle, Th.: Development and Approval of Automated Vehicles: Considerations of Technical, Legal, and Economic Risks. Markus Maurer, Barbara Lenz, Hermann Winner und J. Christian Gerdes (Hg.): Autonomous Driving: Technical, Legal and Social Aspects. s.l.: Springer, S. 589–618. (2016)
42. Yevkin, O.: An Efficient Approximate Markov Chain Method in Dynamic Fault Tree Analysis. In: *Qual. Reliab. Engng. Int.* 32 (4), S. 1509–1520. DOI: 10.1002/qre.1861. (2016)