

Gemeinsamer Schlussbericht

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

Förderkennzeichen	Verbundpartner
19A21051J	DEKRA SE
19A21051C	dSPACE GmbH
19A21051L	LiangDao GmbH
19A21051K	THA Hochschule Augsburg
19A21051I	TÜV Nord Mobilität GmbH
19A21051H	TTTech Auto Germany GmbH
19A21051D	Fraunhofer EMI
19A21051E	IQZ GmbH
19A21051F	JHP GmbH
19A21051G	RA Consulting GmbH

Laufzeit des Vorhabens 01.01.2022 bis 30.06.2025

Projektkoordinator Nora Harlammert, Ursula Kemper / dSPACE GmbH

Email/Telefon UKemper@dspace.de / +49 5251 1638-1748

Version 3.0

Erstellungsdatum 22.08.2025



Inhaltsverzeichnis

<i>Abbildungsverzeichnis</i>	3
<i>Tabellenverzeichnis</i>	5
0 Zusammenfassung.....	6
1 Kurzdarstellung.....	6
1.1 Aufgabenstellung.....	6
1.2 Voraussetzungen des Vorhabens	7
1.3 Planung und Ablauf des Vorhabens	9
1.4 Wissenschaftlicher und technischer Stand	11
1.5 Zusammenarbeit mit anderen Stellen.....	14
2 Eingehende Darstellung	15
2.1 Verwendung der Zuwendung und erzielttes Ergebnis	15
2.2 Nutzen und Verwertbarkeit.....	65
2.3 Bekannt gewordener Fortschritt	68
2.4 Veröffentlichung der Ergebnisse	69
3 Literaturverzeichnis.....	72

ABBILDUNGSVERZEICHNIS

Abbildung 1: Umstrukturierung in Use Case 1-5	10
Abbildung 2: Gemeinsames Foto bei der Abschlussveranstaltung von RDV	19
Abbildung 3: Landing Page der RDV-Projektwebsite	20
Abbildung 4: Beispiel-Architektur nach INYO Setup in RT-CARS.....	23
Abbildung 5: Ausfallrate Radar vs Alter.....	27
Abbildung 6 Schema der erarbeiteten Lösung für die Cloud-basierten Datenmanagement- und Analyse-Services.....	31
Abbildung 7 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).	32
Abbildung 8: Versuchsträger auf dem Testgelände	36
Abbildung 9: Realer Betrieb und virtuelles Szenario.....	37
Abbildung 10: Use Case 1-5.....	40
Abbildung 11: Überblick zu Use Case 1	41
Abbildung 12: Datenpunktverlust, links Original, rechts 50% Verlust	42
Abbildung 13: Schema der Punktwolkenmanipulation mit Perlin Noise	42
Abbildung 14: Exemplarische Auswertung - Perzeptionsalgorithmus mit 60% Trainingsumfang	43
Abbildung 15: Überblick zu Use Case 2	44
Abbildung 16: RT-CARS Reliability mit Hardware (Sensor) Reparaturen	46
Abbildung 17: Markov Modell Wiederherstellung v.s. Austausch	46
Abbildung 18: Ausfallrate für die Radarsensorik von LKW basierend auf HU-Daten.....	48
Abbildung 19: Modularisierung eines Systems	48
Abbildung 20: Benchmark für Markov, MLP und CNN-Modell	49
Abbildung 21: Demonstrative Anwendung des Modells und der Einfluss von Wetter auf die Gesamtzuverlässigkeit.....	49
Abbildung 22: Überblick zu Use Case 3	50
Abbildung 23: Überblick über die externen Kommunikationsschnittstellen eines Fahrzeugs	53
Abbildung 24: Unterschiedliche Einsatzszenarien als Validierungs-Use-Cases.....	54
Abbildung 25: Exemplarisches Dashboard zur selektiven Visualisierung von Fahrzeugdaten	55
Abbildung 26: Anpassungen und Erweiterungen (Mockup) in DiagRA-X.....	56
Abbildung 27: Messungen zu Latenz und Datendurchsatz im Starlink-System	57
Abbildung 28: Aufbau und Eigenschaften des Mobilten Starlink-Systems	57
Abbildung 29: Architektur Bild des Aufbaus	59

Abbildung 30: Ausschnitt aus Präsentationsvideo des TTT-Executor/ TTT-Orchestrator Aufbaus im AD Referenzsystem. 59

TABELLENVERZEICHNIS

Tabelle 1: Projektpartner und ihre Kompetenzen und Erfahrung	7
Tabelle 2: Übersicht Key Performance Indicators	15
Tabelle 3: Technologiereifegraddefinition	17
Tabelle 4: Demonstrator Sensormessfahrzeug	60
Tabelle 5: Demonstrator Inyo Leichtbau Shuttle	60
Tabelle 6: Demonstrator Sensormessfahrzeug RAC-1	61
Tabelle 7: Demonstrator Sensormessfahrzeug RAC-2	62
Tabelle 8: Demonstrator Sensormessfahrzeug RAC-3	63
Tabelle 9: Demonstrator AD Referenzsystem und automatisches AD MW & Computing Test System	64

0 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 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“ agierender Fahrzeuggenerationen wurden anhand eines automatischen AD MW & Computing Test-Systems Erkenntnisse in Bezug auf Testbarkeit, speziell im Middleware-Segment des AD Stacks und der on-board Datenkommunikation, gewonnen.

1 KURZDARSTELLUNG

1.1 AUFGABENSTELLUNG

Kern des Projektes 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 Schwachstellen zur Entwicklung einer Testprozedur sowie die Überprüfung der Leistungsfähigkeit theoretischer Ansätze der Zuverlässigkeitsanalyse im Kontext des autonomen Fahrens. Der Wissenstransfer von theoretischer Analyseansätze 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.

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 aus 6 Unternehmen, davon 4 kleinen und mittleren Unternehmen (KMU) sowie 2 wissenschaftlichen Einrichtungen und 2 Prüforganisationen zusammen. Die Partner und ihre Kompetenzen und Erfahrungen, die für den Projekterfolg essenziell waren, sind in der Tabelle 1 beschrieben.

Tabelle 1: Projektpartner und ihre Kompetenzen und Erfahrung

Partner	Kompetenzen und Erfahrung
DEKRA SE (Prüforganisation)	DEKRA SE bringt als eines der weltweit größten TIC Unternehmen (Testing, Inspection and Certification) seine Erfahrungen im Bezug auf Fahrzeuge und Fahrzeugsystemprüfungen mit ein. Insbesondere wurden die Kompetenzen aus der regelmäßigen technischen Überwachung der Fahrzeuge (HU=Hauptuntersuchung), des homologationsbegleitenden Testen von ADAS/AD-Funktionalitäten und Fahrzeugdomainspezifisches Wissen zu Fahrerassistenzsystemen eingebracht. Aus den Mangelquoten der regelmäßigen technischen Überwachung ließen sich reale Ausfallraten von Bauteilen bestimmen, die als Datengrundlage für ein erweitertes Markov-Modell dienen können.
dSPACE GmbH (Unternehmen)	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 (KMU)	LiangDao ist unter anderem auf die Entwicklung und Nutzung intelligenter Sensorsysteme zur Testung und Validierung autonomer Fahrfunktionen spezialisiert. 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.
THA Hochschule Augsburg (wissenschaftliche Einrichtung)	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.

	<p>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.</p>
<p>TÜV Nord Mobilität GmbH (Prüforganisation)</p>	<p>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.</p> <p>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.</p>
<p>TTTech Auto Germany GmbH (Unternehmen)</p>	<p>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 serienereprobte 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.</p>
<p>Fraunhofer EMI (wissenschaftliche Einrichtung)</p>	<p>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.</p> <p>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 KISME nutzte EMI</p>

	<p>Machine Learning und Künstliche Intelligenz zur Verbesserung und Validierung kritischer Szenarien für autonome Fahrzeuge.</p> <p>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.</p>
IQZ GmbH (KMU)	<p>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).</p>
JHP GmbH (KMU)	<p>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.</p>
RA Consulting GmbH (KMU)	<p>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.</p>

1.3 PLANUNG UND ABLAUF DES VORHABENS

Arbeitspaket Struktur

Im Projekt RDV wurde ein strukturiertes Vorgehensmodell verfolgt, das sich aus 11 Arbeitspaketen (AP) zusammensetzt. Zur Projektsteuerung wurden jedem Arbeitspaket konkrete Meilensteine zugewiesen, die den Fortschritt und die Zielerreichung systematisch überwachen.

- AP 0 – Organisation und High-Level Architektur (Leitung dSPACE GmbH)
- AP 1 – Fahrzeugdatenmanagement (Leitung TTTech Auto Germany GmbH)
- AP 2 – Definition Gesamtzustandsraum (Leitung IQZ GmbH)
- AP 3 – Fehlermodellierung & Absicherung (Leitung JHP GmbH)
- AP 4 – Expertenwissen (Leitung DEKRA SE)
- AP 5 – Industrial Cloud-Datenmanagement und -Analyseservices (Leitung LiangDao GmbH)

- AP 6 – Datenaufbereitung und Vereinheitlichung für Kommunikation SZT und Cloud sowie Telematik-Middle-Ware (Leitung RAC)
- AP 7 – Gesamtsicherheitsmodellierung und Nachweisbedarfsbestimmung (Leitung EMI)
- AP 8 – XiL-Simulation (Leitung dSPACE)
- AP 9.1 – Testfahrten auf dem Testfeld autonomes Fahren Baden-Württemberg mit integriertem TelTaKo-S und Leitsystem TAF (Leitung RA Consulting GmbH)
- AP 9.2 – Aufbau und Integration Forschungsfahrzeug / Proving Ground (Leitung THA Hochschule Augsburg)
- AP 10 – Prozess zum Sicherheitsnachweis im Entwicklungszyklus für hochautomatisierte Fahrzeuge (Leitung THA Hochschule Augsburg)
- AP 11 – Erforschung und Beiträge für die nächsten Generationen AD Systeme SAE Level 4&5, Referenzsystem und automatisches Testen (Leitung TTech Auto Germany GmbH)

Use Case Struktur

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.

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. Diese Use Cases, wie in Abbildung 1 dargestellt, erleichterten zusätzlich sowohl die interne Koordination als auch die externe Kommunikation des Projektfortschritts.

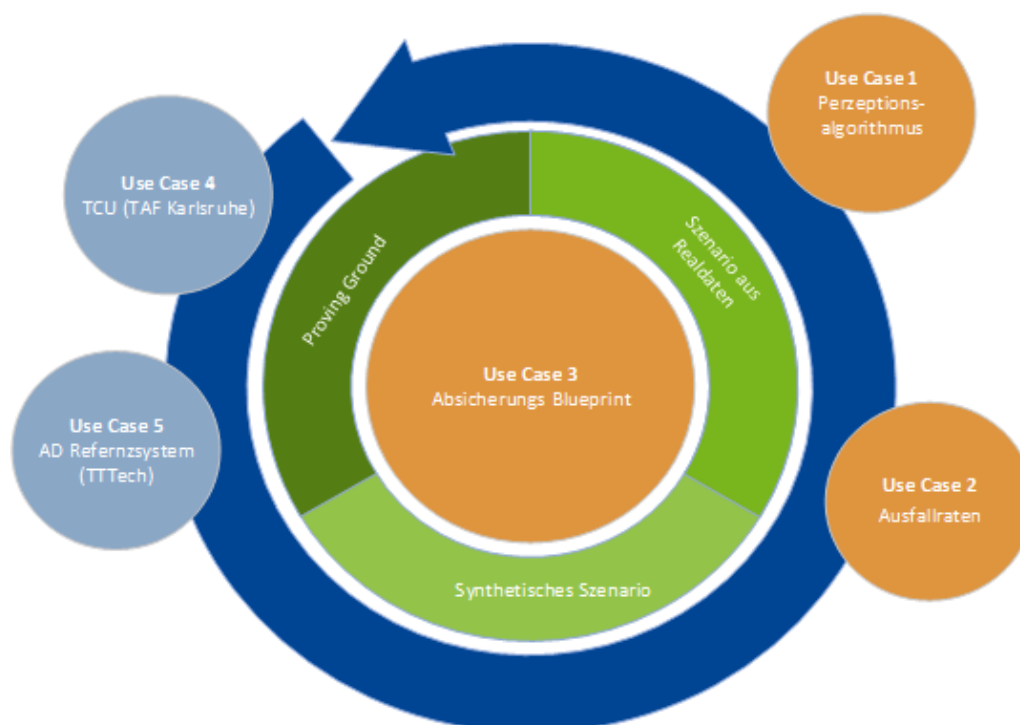


Abbildung 1: Umstrukturierung in Use Case 1-5

1.4 WISSENSCHAFTLICHER UND TECHNISCHER STAND

Die nachfolgende Darstellung beschreibt den Stand der Technik zu 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 Fahrassistenten- 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 Fahrzeug Tests 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 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 Markov-Modellierung, (Talebberouane 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. Für bestehende Systemdesigns dann bottom-up aller FMEA-Varianten und Top-down FTA. 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: AutoMate mit Fokus Analysen zur Effizienz von Mensch-Maschine-Schnittstellen in Übergangssituationen, 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) (Stoewhase 2020) hat sich nicht mit der Weiterentwicklung der Systemanalyseverfahren wie FMDEA, FTA, Markov- und Petri-Netzen beschäftigt (Knoop 2020). 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 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 derzeit 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 Simulationen 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 (Loh und Mock 2020). 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.

KISME 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 Fahrfunktionen 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.

Es war zu Projektbeginn nicht absehbar, dass die vorgesehenen Entwicklungsarbeiten mit bestehenden Patenten außerhalb des Forschungsverbunds in Konflikt geraten könnten. Die Forschungspartner verfolgten eine aktive Patentpolitik und meldeten schutzrechtsfähige Ergebnisse im Rahmen der rechtlichen Möglichkeiten und wirtschaftlichen Vertretbarkeit an.

1.5 ZUSAMMENARBEIT MIT ANDEREN STELLEN

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.

Zusammenarbeit mit anderen Firmen/Einrichtungen

dSPACE und RA Consulting sind Mitglied in der ASAM (Association for Standardization of Automation and Measuring Systems). LiangDao war Mitglied bis Ende 2024. 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 TTTech 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 ([FKZ 19A21044A](#)).

2 EINGEHENDE DARSTELLUNG

2.1 VERWENDUNG DER ZUWENDUNG UND ERZIELTES ERGEBNIS

Entsprechend der dargestellten Zielsetzungen in Abschnitt 1.1 gibt die folgende Tabelle eine detailliertere Übersicht über Schlüsselindikatoren (Key Performance Indicators, KPIs), die innerhalb des Gesamtprojekts adressiert wurden. Darüber hinaus zeigt sie einen Vergleich der Technologiereifegrade (Technology Readiness Levels, TRL) zu Projektbeginn, den geplanten Ziel-TRL sowie den nach Projektende erreichten TRL.

Tabelle 2: Übersicht Key Performance Indicators

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 und 8
2	(Meta) Übergangsmmodellierung 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 Übergangsmmodellierung berücksichtigt werden. Gängige Daten- und Informationsquellen werden abgedeckt. (Expertenquantifizierung).	3 - 6	5 - 7	5
3a	Parametrisierung Übergangsmmodelle durch XiL-Tests. Nachweisbedarf kann gezielt durch XiL-Tests geschlossen werden.	3 - 6	5 - 7	6
3b	Parametrisierung Übergangsmmodelle durch ViL und Labor-Tests einschl. Systememulation. Nachweisbedarf kann	3 - 6	5 - 7	4* und 6

	gezielt durch ViL/Labor-Tests geschlossen werden.			
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
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%), Prioritätstreuung (> 90% für Prio. 1), Verfügbarkeit (>95%), Datenübertragungsrate, Latenzzeit (<1 sek).	3 - 4	6 - 7	4-5* und 6
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	1 - 2	5 - 6	6

	Gesamtsicherheitsmodells verwendet werden können.			
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

***Anmerkung (AP 11):**

Die F&E Inhalte dieses sehr zukunftsorientierten APs der TTTech erreichen wie vorgesehen in RDV lediglich TRL 4-5 und wurden in einer prototypischen Labor-Implementation realisiert. Dies erklärt sich daraus, dass die Inhalte auf Autonomes Fahren für SAE Level 4-5 abzielen, die auch derzeit noch bei weitem keine Serienreife allgemeiner Natur erreichen. Die erzielten Ergebnisse mit dem AD-Referenzsystem und dem angeschlossenen, automatischen Testaufbau (automatisches AD MW & Computing Testsystem) haben aber wertvolle Hinweise geliefert, wie eine Funktionsüberprüfung derart zukünftiger Systeme aufgebaut werden müsste, sobald diese Systeme in Serie gehen würden.

Die Bewertung des Technologiereifegrads (TRL) orientierte sich an der untenstehenden Tabelle, in der jede der neun Stufen (TRL 1–9) durch eine spezifische Definition charakterisiert ist.

Tabelle 3: Technologiereifegraddefinition

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

2.1.1 AP 0 - HIGH-LEVEL ARCHITEKTUR (HLA) UND LEISTUNGSKENNZAHLEN (dSPACE)

Die Organisation und Steuerung des Projekts erfolgte auf Basis klar definierter Kommunikations- und Abstimmungsstrukturen, die eine effiziente Zusammenarbeit zwischen den Konsortialpartnern sowie eine zielgerichtete Umsetzung der technischen Inhalte ermöglichten. Des Weiteren wurde die Entwicklung der High-Level-Architektur, sowie der zugehörigen Messgrößen und eine Vorauswahl zu Methoden und Ansätzen durchgeführt.

Interne Kommunikation

Ein zentrales Element der operativen Projektarbeit war ein zweiwöchentlicher Regeltermin, der über die gesamte Projektlaufzeit hinweg umgesetzt wurde. In diesen Terminen wurden der Fortschritt der einzelnen Partner, offene technische und organisatorische Fragestellungen sowie die nächsten Schritte gemeinsam besprochen. Diese regelmäßige Abstimmung ermöglichte es, frühzeitig auf Herausforderungen zu reagieren, Synergien zwischen Arbeitspaketen zu nutzen und die Umsetzung effizient zu koordinieren.

Zur Unterstützung der verteilten Zusammenarbeit wurde ein gemeinsames Microsoft Teams-Team eingerichtet, das als zentrale Plattform für Kommunikation und Dokumentation diente, sodass eine konsistente und nachvollziehbare Ablage aller relevanten Informationen gewährleistet wurde. Dies erleichterte nicht nur die tägliche Zusammenarbeit, sondern auch die spätere Rückverfolgbarkeit von Entscheidungen und Ergebnissen im Rahmen der Projektbewertung.

Neben der digitalen Abstimmung wurden halbjährlich Konsortialtreffen in Präsenz organisiert, um den persönlichen Austausch zwischen den Partnern zu fördern und strategische Themen gemeinsam zu diskutieren. Diese Treffen boten Raum für technische Deep-Dives, bilaterale Abstimmungen sowie die gemeinsame Reflexion des Projektfortschritts. Sie trugen wesentlich dazu bei, ein gemeinsames Verständnis über die Projektziele und deren Umsetzung zu entwickeln und die Zusammenarbeit über institutionelle Grenzen hinweg zu stärken. Den Abschluss des Projekts bildete eine gemeinsame Abschlussveranstaltung, die bei dSPACE in Paderborn stattfand. Im Rahmen dieser Veranstaltung wurden die finalen Ergebnisse vorgestellt, die Zielerreichung bewertet, Demonstratoren vorgestellt und zentrale Erkenntnisse aus der Projektlaufzeit reflektiert. Darüber hinaus bot die Veranstaltung Raum für den Austausch über mögliche Anschlussaktivitäten und die Weiterverwertung der entwickelten Methoden und Werkzeuge. Abbildung 2 zeigt ein gemeinsames Foto der Teilnehmer der Abschlussveranstaltung auf dem Gelände von dSPACE vor den verschiedenen Demonstratoren.



Abbildung 2: Gemeinsames Foto bei der Abschlussveranstaltung von RDV

Externe Kommunikation

Mit der Übernahme der Projektleitung hatte es sich dSPACE zum Ziel gesetzt eine Projektwebsite zu erstellen. Ziel war es, die Projektinhalte für einen größeren Personenkreise zugänglich zu machen. Projektergebnisse und veröffentlichte Artikel wurden an einer zentralen Stelle gesammelt und mit der Öffentlichkeit geteilt. Das Aufsetzen der Website erfolgte über RA Consulting. Die Inhalte und Struktur lieferte dSPACE. Die Website ist unter www.rdv-projekt.de erreichbar. Die Landingpage ist in Abbildung 3 zu sehen.



REAL DRIVING VALIDATION

Eine kontinuierliche Qualitätsaussage über automatisierte Fahrfunktionen von Level 3 bis Level 5 auf Fahrzeugebene („Grey box“) ist unter umfassender Berücksichtigung aller möglichen Szenarien, Umweltbedingungen und Verkehrsteilnehmer (Gesamtsystem) eine sehr große Herausforderung.

Es bedarf einer zunehmenden Vernetzung sowie einem effizienten Informationstransfer von Wirtschaft, Wissenschaft und Industrie.

Auf Grundlage realer Fahrdaten aus dem Feld sowie aus Hauptuntersuchungen, stellt das Projekt Real Driving Validation eine effiziente und sichere Methodik für Original Equipment Manufacturer (OEM) und Tier-1/ Tier-2 zur Validierung von KI-basierten Fahrfunktionen, zur Verfügung.



Abbildung 3: Landing Page der RDV-Projektwebsite

High Level Architektur

TNM befasste sich mit der Erarbeitung von homologationsrelevanten Anforderungen sowie den dazugehörigen Parametern, um hoch- und vollautomatisierte Fahrzeuge abzusichern. Dazu wurde seitens TNM eine Analyse der geltenden genehmigungsrelevanten Regelwerke, Vorschriften und Normen durchgeführt.

Auf Basis der identifizierten Regelwerke, Vorschriften und Normen sind Prüf- und Sicherheitsanforderungen erarbeitet worden, die in späteren Homologationsverfahren zur Anwendung kommen können. Zudem wurden Anforderungen an den Nachweisbedarf ausgearbeitet, um hoch- und vollautomatisierte Fahrzeuge zu prüfen.

Die spezifizierten Sicherheitsanforderungen stellen eine Grundlage für die umzusetzenden Sicherheitskonzepte und Prüfscenarien des Versuchsträgers dar. Aufgrund der Vielzahl möglicher Szenarien, Situationen und Parameter im öffentlichen Verkehrsraum erfordert eine geeignete Teststrategie sowohl Prüfungen in realer Umgebung als auch den Einsatz simulationsbasierter Prüfumgebungen. Damit simulationsbasierte Prüfverfahren als Teil eines Sicherheitsnachweises argumentierbar sind, müssen die eingesetzten Prüfverfahren, Prüfscenarien und Prüfsysteme nachweisbar die erforderliche Qualität aufweisen. Dabei ist eine hinreichende Repräsentativität des Prüfraums und eine Genauigkeit der Messdaten zu erreichen. TÜV NORD Mobilität spezifizierte daher Anforderungen an die Verfahren und Szenarien zur realen sowie virtuellen Erprobung und Validierung sowie an die eingesetzten Prüfsysteme.

Bewertung der Projektergebnisse

Die Bewertung der Projektergebnisse anhand definierter Key Performance Indicators (KPIs) diente der Erfolgskontrolle und unterstützte die transparente Darstellung des Projektfortschritts. Zu diesem Zweck wurden, die im Projektverlauf durchgeführten Aktivitäten systematisch auf die zu Projektbeginn festgelegten KPIs gemappt. Diese strukturierte Herangehensweise erlaubte eine objektive Bewertung der Zielerreichung in den einzelnen Arbeitspaketen. Ergänzend wurde eine Bewertung des Technology Readiness Levels (TRL) durchgeführt, um den Reifegrad der entwickelten Arbeitsergebnisse und Methoden einzuordnen. Diese Bewertung diente nicht nur der Qualitätssicherung, sondern auch der Vorbereitung auf mögliche Transfer- oder Folgeprojekte. Die TRL-Einstufung ermöglichte eine fundierte Aussage darüber, inwieweit die entwickelten Lösungen bereits in reale Entwicklungsprozesse überführt werden können.

Insgesamt wurde deutlich, dass die gewählte Projektorganisation, bestehend aus regelmäßiger Abstimmung, strukturierter Dokumentation, persönlichem Austausch und systematischer Ergebnisbewertung, einen wesentlichen Beitrag zum erfolgreichen Projektverlauf geleistet hat. Die entwickelten Kommunikationstrukturen und -methoden haben sich als tragfähig erwiesen und bieten eine belastbare Grundlage für zukünftige, vergleichbare Vorhaben. Die Arbeit im Konsortium war geprägt durch ein konstruktives, engagiertes und kooperatives Miteinander aller Partner.

2.1.2 AP 1 – FAHRZEUGDATENMANAGEMENT (TTTECH)

TTTech, Anmerkung: Ursprünglich war in AP 1 geplant, eine Daten Up-stream und Down-stream Lösung sowie eine Data Logging Einrichtung für die Steuerdaten am Fahrzeug zur Verfügung zu stellen. Dieses System wurde auch für die initiale Konfiguration zusammengestellt, konnte dann aber auf die in der Neuausrichtung gewählten Lösung in der Form nicht angewendet werden. Initial für das ILO-Fahrzeug konzipiert war eine Integration in das LiangDao Fahrzeug nach dem Ausstieg von ILO nicht mehr realistisch und somit auch nicht mehr vorgesehen.

Die Arbeiten von dSPACE in UAP 1.1 bestanden darin Messkampagnen im dSPACE eigenen Sensormessfahrzeug durchzuführen. Die aufgezeichneten Daten wurden im Anschluss anonymisiert und annotiert, um sie gelabelt in der Modellierung und Simulation (AP 8) nutzbar zu machen.

In Abstimmung mit den Modellen aus AP 2 und AP 3 sowie durch Diskussionen zu Umweltbedingungen und Parametrisierungen der Übergangsmoedelle wurde in UAP 1.2 die Planung der Testfahrten gemäß AP 10 unterstützt.

In UAP 1.3 wurde an der Schaffung einer skalierbaren Diagnoseoberfläche für die Cloud-basierten Datenmanagement und Analyseservices in AP 5 gearbeitet. Für eine nachvollziehbare Darstellung sind die Ergebnisse zusammen mit jenen aus AP 5 in 2.1.6 dargestellt.

2.1.3 AP 2 – DEFINITION GESAMTZUSTANDSRAUM (IQZ)

Das Ziel von AP 2 lag in der Entwicklung eines Modells zur Bewertung der Sicherheitskritikalität von Verkehrssituationen unter Berücksichtigung von Fahrzeug, Umgebung und weiteren Verkehrsteilnehmern. Dafür sollte ein Gesamtzustandsraum des Fahrzeugs einschließlich Betriebs- und Fehlerzuständen modelliert werden der insbesondere Aspekte moderner, resilienter Fahrzeugarchitekturen, wie ein dynamisches Fehlermanagement (FDIR), beinhaltet. Die Ergebnisse dienen als Grundlage für zukünftige AD-Referenzsysteme (SAE Level 4–5) und die Weiterentwicklung standardisierter, datengetriebener Modellierungsansätze.

Auf Basis der Recherche von geltenden Standards und Normen, Frameworks für Software AD Stacks sowie der E/E Architektur des INYO-Fahrzeuges, konnte eine resiliente Systemarchitektur abgeleitet werden. Diese Grundarchitektur ist mit den anderen Projektpartnern diskutiert, analysiert und verfeinert worden. Dabei erfolgte eine genauere Definition von Soft- und Hardwarekomponente sowie die Erweiterung durch unterschiedliche Betriebsmodi und Redundanzstrukturen. Mithilfe geltender Standards zur Verifikation

und Validierung, Szenarienbildung etc. (bspw. ISO 26262, ISO 21434, ISO/AWI TS 5083, ISO 34502 und ISO TR 34502) ist dann ein Gesamtzustandsraum abgeleitet worden. Neben Redundanzen, beinhalten die Resilienz-Maßnahmen auch die Wiederherstellung (Recovery) aus ausgefallenen Systemzuständen. Für Hardware Komponenten bedeutet dies, dass sowohl Reparaturen klassisch in Form eines Austausches, aber auch moderne Konzepte wie Self-Healing aus dem Bereich des Organic Computing Bereich betrachtet werden. Für Software Applikationen wird ein komplexeres FDIR-Konzept, welches schon lange in der Luft- und Raumfahrt etabliert ist und durch den massiv gestiegenen Einsatz von (automatisierter) Software im Automobilbereich zunehmend an Popularität gewinnt, vorgesehen. Für kritische Software bedeutet dies, dass der durch sie erhaltene Systemzustand im Applikationsausfall über zwei Mechanismen geschützt wird. Erstens wird sofort auf die redundante Software Instanz, welche aktiv mitläuft doch dessen Ausgabe noch ungenutzt ist, gewechselt (falls vorhanden). Damit kann das Wechseln in einen Risiko behafteten Zustands vermieden, oder der Aufenthalt in diesem Zustand enorm verkürzt werden. Im nächsten Schritt, wird versucht die ausgefallene/fehlerhafte Software Instanz wiederherzustellen. In Anlehnung an den FDIR-Prozess muss hierfür zunächst die Fehlerursache identifiziert werden und dann eine geeignete Reparatur gefunden werden (Neustart, Fernwartung, Software-Update, ...). Neben der Risikomodellierung nach ISO 26262 (FuSi), wurde der Gesamtzustandsraum um Risiken aus dem Bereich der ISO 21448 (SOTIF) erweitert, um die Modelltiefe speziell im Bereich der Verknüpfung von Fahrzeug und Umgebungsbedingungen zu verbessern.

Um den so abgesteckten Gesamtzustandsraum inklusive dynamischer, Resilienz-steigernder Fahrzeugkonzepte modellieren und auswerten zu können, wurde ein mathematisches Modell mit simulativer Evaluation des IQZ dahingehend weiterentwickelt, verschiedene Betriebszustände und Zuverlässigkeits-KPI probabilistisch abbilden zu können. Da bereits bestehender Programmcode dieser Simulationsumgebung in Matlab und Eingabemöglichkeit via JSON bestand, wurde das zuvor festgelegte Systembeispiel (INYO) zunächst als JSON Eingabe kodiert.

Um Benutzbarkeit und Komfort sowie die Fehleranfälligkeit und Wartbarkeit zu verbessern, wurde das im IQZ bestehende Matlab Simulationstool zunächst um eine grafische Benutzeroberfläche zur Systemmodellierung mit JSON-Konverter erweitert. Die Applikation wurde in C++ unter Verwendung des Qt-Frameworks entwickelt. Im weiteren Projektverlauf, wurde entschieden anstatt einer automatischen Anbindung an das Matlab backend, das Simulationsbackend ebenfalls in C++ zu überführen und so ein stand-alone Programm zu schaffen. Entscheidende Gründe waren letztendlich ein großer Effizienz- und Performanzgewinn der Auswertungslogik, die vereinfachte Nutzung und Installation sowie die verbesserte Wartbarkeit. Im Zuge dessen sind einige Verbesserung an der Simulationslogik vorgenommen worden und der Code ist grundsätzlich. Damit soll die Nachhaltigkeit im Sinne einer langfristigen Nutzung gefördert werden.

Die in C++/QT-basierte Applikation „RT-CARS“ ermöglicht es nun dem Benutzer ein System auf Komponentenebene zu modellieren. Dafür lassen sich komfortabel via Drag-and-drop Hardware Komponenten (Chips, Sensoren und Switches) definieren und die Datenverbindungen zwischen diesen, welche bspw. BUS- oder Ethernet-Verbindungen darstellen, bequem über das Setzen von Konnektoren erstellen. Software Komponenten können in einem separaten Fenster mit umfänglichen Parametern, wie bspw. benötigte Ressourcen und Eingabesignale, angelegt werden. Des Weiteren hat der Benutzer die Möglichkeit verschiedene Ausfallmodelle mit unterschiedlichen Raten bspw. Weibull-verteilt, exponentialverteilt oder zu einer fixen Rate, zu definieren, welche auch in einer lokalen Datei zur Wiederverwendung abgespeichert werden. In erster Linie sind hier klassische (FuSi) Fehler adressiert und es gibt die Möglichkeit, pro Fehler eine Reparaturrate zu definieren. Über das Einstellungsfenster der Hard- und Softwarekomponenten können die angelegten Fehlermodi gesetzt werden. Da pro Komponente beliebig viele Fehlermodi definiert werden können, und die Reparaturen unabhängig voneinander sind, besteht hier jedoch auch eine erste Möglichkeit auch transiente Fehler, wie temporäre Sensorausfälle durch Verschmutzung etc. abzubilden (SOTIF). Die Modellierung von Redundanzen erfolgt über die

Definition von Redundanzgruppen. Dabei sind Software und Hardware getrennt worden, da davon ausgegangen worden ist, dass Hardware und Software Komponenten keine äquivalenten Aufgaben erfüllen können (Software benötigt immer Hardware auf der sie ausgeführt werden kann). Außerdem kann der Benutzer definieren, welche Signale im System mindestens vorhanden sein müssen, damit die Minimalanforderungen erreicht werden. Dies ist essentiell für die nachgesetzte Simulation, da darüber das Zuverlässigkeitsziel abgeleitet wird. Modellerte Systeme lassen sich im XML-Format Speichern und Laden, sodass der Austausch des Modells und dessen Erweiterung nun einfach möglich ist.

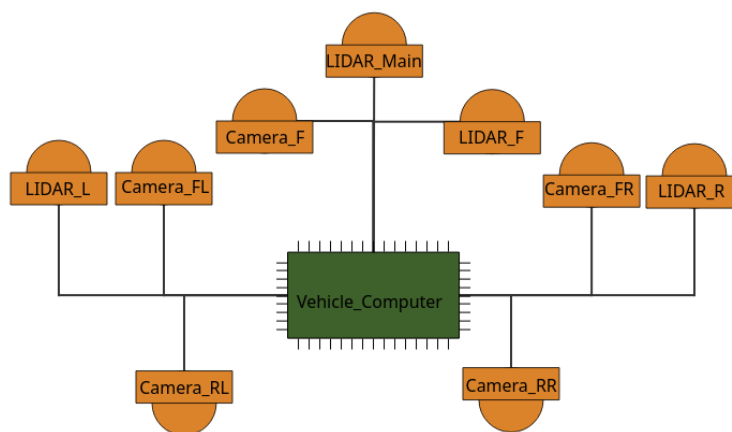


Abbildung 4: Beispiel-Architektur nach INYO Setup in RT-CARS

Für die Systemauswertung wird eine Simulation nach der Monte-Carlo Methode ausgeführt. Die Anzahl der Iterationen, anvisierte Lebenszeit etc. sind vom Nutzer individuell zu bestimmen. RT-CARS simuliert dabei Ausfallzeitpunkte der modellierten Komponenten und bildet den FDIR(O) (Failure Detection, Isolation, Recovery) Prozess inkl. Optimization-Step für die Platzierung der wiederhergestellten Software ab. Für die Ergebnisauswertung werden dem Benutzer je nach Einstellung detaillierte Ereignislogs bereitgestellt. Auf Basis dieser Logs, sind verschiedene Analysen zu Zuverlässigkeits-KPI bereits implementiert: Ausfallwahrscheinlichkeit, Zuverlässigkeit, Verfügbarkeit. Außerdem bietet RT-CARS die Möglichkeit zur Parameterabschätzung für verschiedene Verteilungsfunktionen sowie Detail-Auswertungen wie die Anzahl an durchgeführten Software Verschiebungen und Wiederherstellungen.

Der Fokus der Modellierung in RT-CARS liegt in der Sicherheit und Zuverlässigkeit des Fahrzeugs. Bis dato kann RT-CARS keine Safety-Risiken durch Ausnutzen von Vulnerabilitäten abbilden (Cybersecurity). Um diese jedoch in der Gesamtsystemmodellierung nicht untergehen zu lassen, wurde die Integration in ein Markov-basierten Model-checking Ansatz (PRISM) erfolgreich geprüft. Eine Automatisierung von RT-CARS ausgehend, ist jedoch nicht weiterverfolgt worden. Des Weiteren werden Umgebungseinflüsse wie Wetter etc. in RT-CARS nicht adressiert. Die Markov-Modellierung des EMI ist in der Lage sowohl Systemzustände als auch Wetterfaktoren in einem Modell zu betrachten. Um den modellierbaren Gesamtzustandsraum zu erweitern, kann eine Integration mit der EMI Modellierung durchgeführt werden. Dafür musste zunächst gesichert sein, dass beide Modellierung trotz offensichtlicher semantischer Unterschiede, bei gleichen Eingaben, ähnliche bis gleiche Ergebnisse liefern. Diese gegenseitige Verifikation konnte in Use Case 2 erfolgreich gezeigt werden.

2.1.4 AP 3 – FEHLERMODELLIERUNG & ABSICHERUNG (JHP)

AP 3 der Vorhabensbeschreibung befasste sich mit der Fehlermodellierung und der Ableitung von Übergangs- und Ausfallmodellen auf der Ebene von Teilsystemen des Gesamtzustandsraums autonomer Fahrzeuge.

Der Unterarbeitspunkt UAP 3.1 befasste sich mit der Bereitstellung von Ereignis- und Ausfallraten für Hardwarebausteine und Softwarebestandteile. In der ersten Phase des Projektes verlagerte sich der

Fokus UAP 1 betreffend. Im Vordergrund des RDV-Projektes stand aus fachlicher Sicht die Safety of the Intended Function (SOTIF). Bei dieser spielen Hardwareaspekte keine so große Rolle mehr wie bei der funktionalen Sicherheit. Zudem werden mittlerweile viele hardwarebasierte Fehlerbilder, wie z.B. Soft Errors, sehr gut beherrscht durch entsprechende Lösungen (z.B. Lock-Step). Die Kenntnis von Ausfallraten für Hardware ist insbesondere für den Aspekt einer Gesamtzustandsraum-Modellierung und spezifische Berechnungen darin von Bedeutung.

Im Rahmen von UAP 1 wurde zusammen mit dem Projektpartner dSPACE an der Fragestellung gearbeitet, ob es einen statistischen Ansatz gibt, um mit bisher unbekanntem Fahrverhalten innerhalb der ODD umzugehen. Diese Szenarien stellen insbesondere im Kontext von SOTIF eine große Herausforderung dar.

Im Rahmen der Zusammenarbeit mit dSPACE in AP 11 konnte JHP ein statistisches Modell entwickeln, welches basierend auf den Ergebnissen einer durchgeführten Messfahrtkampagne eine Auftretensrate für bisher unbekanntem Szenarien ermittelt. Die Basis für den statistischen Ansatz ist ein sog. nichthomogener Poisson-Prozess. Ein entsprechendes Modell kann mit projektspezifischen Daten aus Messkampagnen angepasst werden und bietet somit praktische Verwendbarkeit. Hiermit ist es möglich, einen quantitativen Beitrag im Rahmen der Sicherheitsanalyse von autonomen Fahrzeugen zu liefern.

Die gesamtheitliche Darstellung der Zusammenhänge und Ergebnisse erfolgte in einer Fachzeitschriftveröffentlichung (V11).

Es wurde eine umfassende Recherche zu den Ausfallwahrscheinlichkeiten unter verschiedenen (Umwelt)Bedingungen durchgeführt. Diese wurden im Rahmen einer Veröffentlichung (V17) für die Nutzung mit dem Markov-Modell angepasst. Außerdem wurde mit dem Projektpartner die Ermittlung von Ausfallraten auf Grundlage von vorliegenden Datenbanken diskutiert. Hier wurde als konkretes Beispiel die Ausfallrate für die Radarsensorik, basierend auf den HU-Daten der DEKRA, ermittelt. Dafür wurden alle LKWs mit Erstzulassung ab 2018 herangezogen, da diese zwingend mit Radarsensorik ausgestattet sein müssen. Die Daten umfassten auch die Laufleistung der LKWs, wodurch die Erstellung einer zeitabhängigen Ausfallrate in Abhängigkeit vom Alter der Sensorik ermöglicht wurde. Die Messdaten wurden durch eine Weibullkurve angenähert. Auf diese Weise können Kurven für die Ausfallraten von Sensorik erstellt werden, sofern die entsprechenden Daten vorliegen.

Zum Aspekt der Gesamtzustandsraummodellierung fand eine intensive Zusammenarbeit der Projektpartner statt. Im Zentrum der Diskussion standen hier die Einflussparameter, welche nötig sind, um das Ausfallverhalten autonomer Fahrzeuge zu beschreiben. Die Diskussion dieses Themas führte zu einem gemeinsamen Verständnis der Gesamtheit und war ein guter Ausgangspunkt für die weiteren Arbeiten. Das Ausfallverhalten eines autonomen Fahrzeuges wird einerseits vom System selbst (Hard- und Software) aber auch von der den Umgebungs- (z.B. Wetter, Sonnenstand) und Nutzungsbedingungen (konkrete Fahrsituation: innerstädtischer Verkehr mit hohem Verkehrsaufkommen und vielen Objekten, welche der Perzeptionsalgorithmus erkennen muss) definiert. Diese Vielschichtigkeit führt im Hinblick auf die Modellierung des Gesamtzustandsraumes zu einer sehr hohen Komplexität. Aus Technologiesicht verschob sich der Fokus aus den genannten Gründen weg von der Hardware und hin zur Software. Insbesondere der Umstand, dass die Software eines autonomen Fahrzeuges permanent funktionieren muss unter allen Nutzungsbedingungen macht die Software für autonome Fahrzeuge sehr bedeutend. Hinzu kommt, dass Teile der Software KI-basiert sind und nicht mehr im klassischen Sinne programmiert werden. Dies bedeutet in der Gesamtheit, dass die Absicherung solcher Software bzw. Funktion nicht mehr nur auf sog. anforderungsbasierten Tests basieren kann, da die Vollständigkeit der Anforderungen selbst Teil der Absicherung ist (Kenntnis des ODDs und Identifikation der relevanten Fahrverhalten).

UAP 2 befasste sich intensiv mit der Zuverlässigkeit der Software in autonomen Fahrzeugen. Hier spielte das Thema der „Absicherung“ eine bedeutende Rolle. Hierbei kann der Begriff „Absicherung“ sowohl aus

Performance- als auch aus Sicherheitssicht verstanden werden. Es wurden zu diesem Themenkomplex zwei Punkte im Rahmen von UAP 2 bearbeitet.

Im Rahmen einer Zusammenarbeit der Projektpartner LiangDao, IQZ, dSPACE und JHP wurden Validierungsdaten von Perzeptionsalgorithmen verschiedener Trainingsstände statistisch ausgewertet. Hierbei wurde die komplette Verarbeitungskette prototypisch aufgebaut von der Rohdatengewinnung, der Datenvorverarbeitung, der Datenmanipulation und der statistischen Auswertung zur Ableitung von entwicklungsrelevanten Informationen bzgl. Erprobung und Optimierung. Es zeigte sich das die Gütekriterien Precision und Recall einer statistischen Auswertung zugänglich sind und meist mit einfacher Normalverteilungsstatistik bearbeitet werden können. Die durchgeführten Arbeiten zeigen auf, dass die die Performance von Perzeptionsalgorithmen während des Entwicklungsprozesses statistisch bewertet werden können. Dies erlaubt reproduzierbare Bewertung von Verbesserungspotentialen, die Identifikation von Leistungsgrenzen und die Ursachenidentifikation von Sachverhalten.

Im zweiten Punkt zum Thema „Absicherung“ wurde untersucht, ob autonome Fahrzeuge weniger Unfälle verursachen als menschliche Fahrer. Diese Forderung ist relevant im Hinblick auf die Akzeptanz und Zulassung autonomer Fahrzeuge. Es wurde ein statistischer Vergleich zwischen fahrerlosen Fahrzeugen und menschlichen Fahrern durchgeführt. Eine große Schwierigkeit dabei ist es, eine vergleichbare Datenbasis von menschlichen Fahrern und autonomen Fahrzeugen mit ähnlichem Fahrverhalten und vergleichbarem ODD (Operational Design Domain) zu schaffen. Während der letzten Jahre wurden Tests mit autonomen Fahrzeugen auf öffentlichen Straßen durchgeführt, wobei eine große Anzahl von gefahrenen Meilen zurückgelegt wurde. Die Datenbank des California Department of Motor Vehicles (DMV) enthält Informationen über autonome Fahrzeuge und ihre Unfälle sowie über Disengagements, wenn der/die Testfahrer/-in übernehmen muss. Eine solide und umfassende Datenbasis lieferte die fahrerlose Waymo Flotte, die als Robotaxis in San Francisco betrieben wurde. Eine vergleichbare Datenbasis für menschliche Fahrer liefert eine im September 2023 veröffentlichte Fallstudie. Es wurden über einen Zeitraum von zwei Jahren Unfalldaten sowie Laufleistungen von menschlichen Fahrern aus “ridehail“ Fahrdiensten im selben Gebiet von San Francisco gesammelt und Unfallraten zur Verfügung gestellt. Eine vergleichbare Datenbasis war somit gegeben.

Im Rahmen dieses Arbeitspunktes konnte gezeigt werden, dass der praktische Feldnachweis, dass autonome Fahrzeuge weniger Unfälle verursachen als menschliche Fahrer zumindest im Stadtverkehr sowohl fachlich als auch praktisch möglich ist. Die entsprechenden statistischen Methoden aus der Zuverlässigkeitstechnik liegen vor und wurden auf die vorliegenden Daten angewandt. Zu diesem Thema entstand eine Veröffentlichung (V12).

UAP 3 befasste sich intensiv mit der Modellierung des Ausfallverhaltens autonomer Systeme. Im Verlauf des Projekts wurden verschiedene Daten- und Informationsarten identifiziert, die in der praktischen Anwendung von Bedeutung sind. Diese Aspekte wurden in enger Zusammenarbeit mit den Projektpartnern, insbesondere im Rahmen von Use Case 2, ausführlich diskutiert.

Im Rahmen von Use Case 2 wurden wetterabhängige Übergangsmodelle erfolgreich in die Simulation integriert. Diese Modelle wurden weiterentwickelt und für die Verwendung mit realen Daten optimiert. Durch die Anpassung an tatsächliche Bedingungen konnten die Modelle präziser gestaltet werden, was zu einer verbesserten Vorhersagegenauigkeit und einer realistischeren Abbildung des Ausfallverhaltens unter variierenden Wetterbedingungen führte.

2.1.5 AP 4 – EXPERTENWISSEN (DEKRA)

In AP4 sollen vorhandene Erfahrungen und Informationen aus der homologationsbegleitenden Absicherung/Validierung und der Typprüfung von Fahrzeugen aber auch verdichtete Informationen und Ergebnisse aus regelmäßigen Sicherheitsuntersuchungen nach StVZO als wertvolle Informationen und Input für das Gesamtprojekt dienen. Ergänzt werden soll dies durch Auswertungen von

Unfalldatenbanken. Durch das Sichten und Auswerten solcher Daten können Fehlerhäufigkeiten ermittelt oder abgeschätzt werden.

UAP 4.1 beschäftigte sich mit der Ermittlung und Definition von relevanten Fahrzeugen (Hersteller und Typ) und relevanten Fahrzeugsystemen. Die Daten von durchgeführten Hauptuntersuchungen nach §29 StVZO – nachfolgend als „HU“ bezeichnet werden anhand dieser Definitionen verdichtet und ausgewertet. Durch eine statistisch relevante Datenmenge kann auf den Fahrzeugbestand hochgerechnet werden. Für die Auswertung und Validierung von HU Daten und HU- ähnlichen Daten sind die relevanten Systeme identifiziert worden. Die Hauptuntersuchung nach §29 StVZO ist eine technische Untersuchung von zulassungspflichtigen Fahrzeugen, welche die Fahrzeughalter in regelmäßigen Zeitabständen von dafür anerkannten Überwachungsorganisationen oder Technischen Prüfstellen durchführen lassen müssen. Zweck dieser Untersuchung ist es die Verkehrssicherheit sowie die Umweltverträglichkeit der Einzelfahrzeuge und damit natürlich auch der gesamten Fahrzeugflotte über die gesamte Fahrzeuglebenszeit weitestgehend zu gewährleisten.

Im Fokus stehen die nach EU-Verordnung EU(VO) 2019/2144 für bestimmte Straßenfahrzeuge vorgeschriebenen Assistenzsysteme. Diese EU-Verordnung, bzw. die relevanten Systeme werden häufig auch als GSR bzw. GSR-Systeme bezeichnet (Global Safety Regulation).

Nach dieser EU-Verordnung sind für neue Fahrzeugtypen, bzw. neue Fahrzeuge (Erstzulassung) ab den folgenden Daten bestimmte Systeme vorgeschrieben und sind somit vom Fahrzeughersteller ab der Auslieferung zu verbauen:

- 06. Juli 2022 für neue EU-Typgenehmigungen (neue Fahrzeugtypen)
- 06. Juli 2024 für erstmaliges in den Verkehr bringen (Erstzulassungen)

Die angegebenen Daten sind die jeweils spätestens anzuwendenden Daten.

Die zu diesen Daten vorgeschriebenen Assistenzsysteme sind:

- a) intelligenter Geschwindigkeitsassistent
- b) Vorrichtung zum Einbau einer alkoholempfindlichen Wegfahrsperre
- c) Warnsystem bei Müdigkeit und nachlassender Aufmerksamkeit des Fahrers
- d) hochentwickeltes Warnsystem bei nachlassender Konzentration des Fahrers
- e) Notbremslicht
- f) Rückfahrassistent
- g) ereignisbezogene Datenaufzeichnung (event data recorder)

Zusätzlich müssen Fahrzeuge der Kategorien M1 und N1 über folgende Systeme verfügen:

- hochentwickeltes Notbremsassistentensystem
inklusive Erkennung von Hindernissen, bewegten Fahrzeugen, Fußgängern und Fahrradfahrern
- Notfall-Spurhalteassistentensystem (Emergency Lane Keeping System)

Die Fahrzeugklassen/Kategorien sind nach der Rahmenverordnung für Typprüfungen EU(VO) 2018/858 definiert. Kategorie M1 sind PKW und Kategorie N1 sind leichte Nutzfahrzeuge, jeweils bis zu einem zulässigen Gesamtgewicht von max. 3,5 Tonnen.

Für den Kernbereich „Auswertung und Validierung von HU-Daten“ müssen die Fahrzeuge der HU unterzogen werden. Die erste HU wird bei Fahrzeugen der Klasse M1 nach 3 Jahren und für Fahrzeuge der Klasse N1 nach 2 Jahren durchgeführt. Alle nachfolgenden Untersuchungen finden im Abstand von jeweils 2 Jahren (24 Monate) statt. Diese Prüffristen sind in Deutschland nach § 29 StVZO Anlage VIII festgelegt. Der Umfang, die Prüfpunkte sowie ggf. Ergänzungsuntersuchungen sind in § 29 StVZO Anlage VIIIa definiert.

Anzumerken ist, dass eine spezifische oder gezielte Untersuchung von Fahrerassistenzsystemen nach § 29 StVZO Anlage VIIIa bisher nicht erfolgt. Eine Untersuchung dieser Systeme findet bisher nur durch eine allgemeine Sicht- und Zustandsprüfung sowie ggf. Fehlfunktionsanzeigen oder/und durch das Auslesen von Fehlerspeichern über die Fahrzeugeigene sog. OBD-Schnittstelle statt (Fahrzeugdiagnose-Schnittstelle).

Um die Chance auf Ergebnisse zu erhöhen, werden die Systeme auf die Sensoriken heruntergebrochen, welche die Eingangsgrößen für die Assistenzsysteme bereitstellen. Diese sind bereits seit längerem in den Fahrzeugen verbaut. Die verwendeten Sensoriken sind: Radar (Nah- und Fernbereichsradar), Lidar, Kamera, und Ultraschallsensoren. Diese wurden ebenfalls näher betrachtet, um später abschätzen zu können, welche Daten beobachtet werden müssen, um eine Aussage in Richtung Funktionssicherheit treffen zu können.

Analysiert man die Datenbankstruktur und setzt die sich ergebenden Randbedingungen kann mit der HU Datenbank Analyse ein erheblich relevantes Ergebnis für RDV erzielt werden. Hier lassen sich durch die Auswertung einzelner Bauteil IDs (BTIDs) z.B. für den Radarsensor, gezielt Ausfallraten berechnen die als Eingang des Markov Modells in Use Case 2 verwendet werden können. Als exemplarisches Beispielergebnis sind die Ausfallraten des Bauteils Radarsensor über das Fahrzeugalter in Abbildung 5 dargestellt.

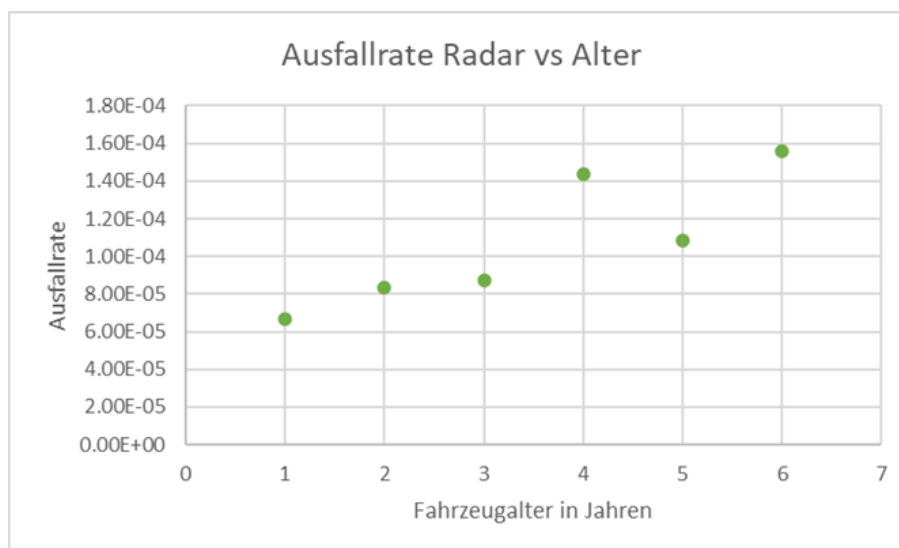


Abbildung 5: Ausfallrate Radar vs Alter

Diese Ausfallraten können direkt als Eingang der Markov Modellierung verwendet werden. Die Qualitative Abschätzung der Gesamtfahrzeugmenge als Referenz lässt sich als einzige potenzielle Fehlerquelle identifizieren. Um diese zu umgehen, wurde für die Markov Modellierung nur Realdaten von NFZ (Nutzfahrzeugen) verwendet die solch ein System in relevanten Untersuchungszeiträumen besitzen müssen. Als Ergebnis kann, festgehalten werden, dass die HU Datenbank Ausfallraten für

Sensoren liefern kann, sofern die Auswerteparameter gezielt gewählt werden. Damit wäre eine Rückführung von Realdaten aus dem Feld in die Neuentwicklung von ADAS-Systemen möglich.

In UAP 4.4 sollen für eine zukünftige Hauptuntersuchung an relevanten Fahrzeugen mit sicherheitsrelevanten Assistenzsystemen ist die Auswertung, Befundung und Einstufung von fahrzeugeigenen Diagnosedaten mindestens als Ergänzung zu einer Funktionsprüfung sinnvoll und notwendig. Für notwendige Festlegungen durch die (EU-)Gesetzgebung oder Normierungen z.B. nach ISO 20730-1 oder nach ISO 20730-3 ("ePTI"), sind die Parameter und Inhalte zu definieren und zu strukturieren. Hierfür sind vorhandene Assistenzsysteme analysiert worden und mit verschiedenen Diagnosesystemen an der Diagnoseschnittstelle Parameter erhoben worden. Die Aufteilung erfolgt auf Basis der herstellerseitig implementierten Diagnosefähigkeit der Systeme. Auffällig hierbei ist, dass die Systeme oft nach Sensoriken mit wahlweise einem oder mehreren Fahrerassistenzsystemsteuergeräten aufgeteilt sind. Die auslesbaren Parameter variieren stark von Hersteller zu Hersteller. Eine Untersuchung im Projekt ergab, dass mit Hersteller- und Mehrmarkendiagnosegeräten einige Parameter ausgelesen werden können. Diese sind aber nicht standardisiert auslesbar. Noch geringer wird die Menge der auslesbaren Daten über die OBD-Schnittstelle, bei den von Sensoriken auf den internen Fahrzeugbus gesendeten Daten. Denn nur weil einem Sensor/Steuergerät Parameter zur Verfügung stehen bedeutet dies nicht, dass diese auch über den OBD-Anschluss auslesbar sind. Da die physikalischen Größen der Sensoriken und auch die durch die Untersuchung bekannt gewordenen Parameter vorhanden sind, lässt sich daraus eine geclusterte Parametertabelle erstellen. Diese lässt sich sortieren nach Assistenzsystem oder Sensorik. Eine Ordnung nach Relevanz für eine zukünftige Standardisierung oder gesetzliche Regelung, kann nur nach bekannt sein der Prüfmethodik erfolgen.

In UAP 4.2 und 4.3 soll zum einen Anhand der Ergebnisse aus UAP 4.1 (HU-Daten) eine erste Abschätzung der Fehlerhäufigkeiten erfolgen. Diese Informationen sollten jedoch ergänzt werden durch Expertenwissen, Erfahrungen sowie ggf. durch Informationen aus Unfalldatenbanken (schwere Unfälle) oder weiterer Quellen (z.B. Reparaturen, Ersatzteilverkäufe, usw.). Somit kann eine weitaus bessere Abschätzung der Fehlerhäufigkeit erfolgen. Weiterhin sollen die Erfahrungen und das Wissen aus durchgeführten Absicherungsmessungen und Typprüfungsmessungen mit eingebracht werden soweit dies aus Geheimhaltungs- und Compliance-Gründen im Rahmen des Projektes möglich ist. Für UAP 4.2 wurde u.a. die German In-depth Accident study (GIDAS) Datenbank analysiert und versucht die Erkenntnisse auf die Fehlerhäufigkeiten zu übertragen. Die Detailtiefe der Daten kombiniert mit dem Fakt, dass diese Daten immer sehr Fallspezifisch sind, erschweren eine Anreicherung der Daten aus UAP4.1.

TÜV NORD Mobilität hat dann aus Unfalldatenbanken, vorhandenen Erfahrungen und Ergebnissen aus Sicherheitsuntersuchungen Informationen gesammelt, um diese im RDV-Projekt einzubringen. Dabei erstellte TÜV NORD Mobilität eine Datenbank für mögliche Szenarien, die in Form eines Szenarien Katalogs gesammelt wurden.

Für die Erhebung und Auswertung von Mängel- oder Ausfallstatistiken im Rahmen von entwicklungsbegleitenden Validierungsmessungen oder der Typprüfungsbegleitenden Absicherungsmessungen (COP - conformity of production) wurde im Rahmen des AP4.3 eine Analyse der zu erhebenden Daten durchgeführt. Dekra hat hier im Rahmen des Projektes keine Möglichkeit effizient Historiendaten oder Statistiken auszuwerten. Dies ist dem Umstand geschuldet, dass DEKRA – sowie alle anderen hierfür akkreditierten „Technischen Dienste“ - zwar die Daten zum Teil generiert, jedoch kein Eigentum an den Daten hat. Diese Daten und Informationen unterliegen strengsten Datenschutz- und Compliance-Vorschriften und sind natürlich „Wissen“ und „Knowhow“ des Fahrzeugherstellers bzw. der

Systemlieferanten (TIER-1). Solche Daten und Informationen könnten ggf. durch die für Deutschland zuständige Zulassungsbehörde KBA-Kraftfahr-Bundesamt zur Verfügung gestellt werden. Da diese Behörde jedoch ebenfalls den gleichen Vorschriften unterliegt wird der Zugang zu solchen Daten praktisch ausgeschlossen sein, bzw. nur über den Fahrzeughersteller selbst möglich sein. In jedem Fall unterliegen diese Daten keiner Standardisierung und sind damit sehr Herstellerindividuell.

In UAP 4.5 soll ein exemplarisches fahrzeugbezogenes Gesamtsicherheitsmodell aufgebaut werden. Hauptanforderungen aus DEKRA-Sicht sind die Umsetzbarkeit einer technisch sicheren und machbaren Lösung innerhalb von Prüfprozessen, die im Rahmen und nicht im Konflikt mit geltenden Richtlinien, Verordnungen oder technischen Normen stehen. Die zu betrachtende Prozesse der Typprüfung und der HU (Hauptuntersuchung) sind vom Inhalt und vom technischen und zeitlichen Aufwand her deutlich zu unterscheiden. Dennoch hängen sie für dieses Themengebiet eng zusammen, denn die rechtlichen Vorgaben und zu berücksichtigende Normen aus der Typprüfung bilden ebenso die Grundlagen für die HU. Die bisherigen Erkenntnisse lassen den Schluss zu, dass die jeweiligen Anforderungen allgemein zu formulieren sind. Die Option an einem Beispielfahrzeug Typprüfungs- oder HU-Verfahren anzuwenden, bleibt jedoch bestehen.

Da wie vor beschrieben in § 29 StVZO Anlage VIIIa sowie in der entsprechenden EU-Richtlinie bisher keine spezifische Untersuchung von ADAS/AD-Systemen durchgeführt wird, diese Systeme jedoch für die Verkehrssicherheit und damit zur Vermeidung und Reduzierung von Unfall-Toten oder schwer Verletzten verpflichtend eingeführt wurden ist die Funktion dieser Systeme äußerst relevant. Für die speziellen Anforderungen der HU wird seitens DEKRA eine weitgehend statische Prüfmethode bevorzugt, die im Rahmen der Vorgaben bezüglich Zeit und Aufwand machbar und akzeptabel ist. Anzustreben ist ein bestmögliches Verhältnis von Resultat/Aussage zu Aufwand. Das Einführungskonzept besteht aus einer Verbauprüfung und einer visuellen Beschädigungsprüfung. Nachgelagert erfolgt eine Prüfung der Integrität der verbauten und relevanten Software sowie in einem weiteren Schritt einer Funktions- und Genauigkeitsprüfung der Sensoriken. Der Grundgedanke für dieses Stufenkonzept ist, dass nach der Typprüfung und den entsprechenden Validierungs- und Absicherungs-Untersuchungen (siehe vor) Software-Stände und Dateninhalte (sog. Kalibrierungen) festgelegt sind. Sofern die Software und deren Integrität (Version, Prüfsumme(n), etc.) unverändert ist und die „Hardware“ (Sensoriken und die sie umgebenden Bauteile) offensichtlich unbeschädigt und „genau“ ist, ist anzunehmen, dass im Rahmen der HU die ADAS/AD-Systeme funktional sind und auszeichnend „genau“. In einem späteren weiteren Schritt könnte auch eine Wirkungsprüfung der Systeme (z.B. Notbremsassistent) erfolgen. Erfahrungsgemäß sind solche Prüfungen jedoch mit großem Aufwand verbunden.

Zu ergänzen hier ist, dass bestimmte Voraussetzungen notwendig sind. Diese sind:

1. Relevante Parameter müssen auslesbar sein, dies muss standardisiert und nachvollziehbar sein:
 - longitudinaler Abstand zum erkannten Objekt
 - Winkel des erkannten Objektes
 - Relativgeschwindigkeit
 - Relevante Softwareversion inkl. Checksummen, Kalibration, ...
(genaue Definition geht aus AP4.4 hervor)
 - Ansätze finden sich in der ISO ePTI (ISO 20730-1,2021; 20730-3,2021)
2. Aktivierungs-Mode: Statische Methode, ADAS / Sensoren müssen aktiv sein; Keine Interferenzen / Einflüsse durch z.B. Sensorfusion.

Durch TÜV NORD Mobilität wurden außerdem Informationen zu Prüf- und Bewertungskriterien, die in der Fahrzeughomologation angewendet werden, zusammengestellt. Auf Basis der gesammelten

Informationen entwickelte TÜV NORD Mobilität ein exemplarisches Sicherheitsmodell für die Typprüfung.

Für Zukünftige Over the Air Updates identifizierte TÜV NORD Mobilität, anhand der durchgeführten Analyse von Prüfanforderungen sowie Homologationsanforderungen, Handlungsempfehlungen, die zum Einsatz kommen können. Im Rahmen von RDV hat TÜV NORD Mobilität Sicherheitsanforderungen, Prüfanforderungen und Testszenarien für das automatisierte und vernetzte Fahren entwickelt. Auf Basis der Forschungsergebnisse werden Schlussfolgerungen und Handlungsempfehlungen abgeleitet, die in künftige Sicherheitsnormen und Genehmigungsvorschriften für das automatisierte und vernetzte Fahren, sowie speziell beim Einsatz von KI-basierten Lösungen in der Fahrzeugtechnik, berücksichtigt werden sollen.

2.1.6 AP 5 – INDUSTRIAL CLOUD-DATENMANAGEMENT UND -ANALYSESERVICES (LIANGDAO)

Ziel des Arbeitspaket 5 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. (UAP 5.1, UAP 5.5 und UAP 1.3).

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 ergänzt.

Die Konformität der Lösung mit europäischen Datenschutzstandards wurde in AP 5.2 geprüft und sichergestellt. Da die übertragenen Objektlisten keine personenbezogenen Daten oder identifizierbare Merkmale wie Kennzeichen enthalten, sind die Datensätze intrinsisch DSGVO-konform.

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: Bielefeld, Sachsen-Anhalt) und ist TISAX-zertifiziert, einem 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 (Projekt-intern) 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.

In den Arbeitspaketen 5.3, 5.4 und 1.3 entwickelte LiangDao die Details der Cloud-Architektur und implementierte zentrale Komponenten, darunter Algorithmen, Analyse-Services und ein Dashboard zur Visualisierung der verarbeiteten Daten.

Die erarbeitete Lösung (siehe Schema in Abbildung 1) basiert auf einer Cloud-Plattform, die über eine 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.

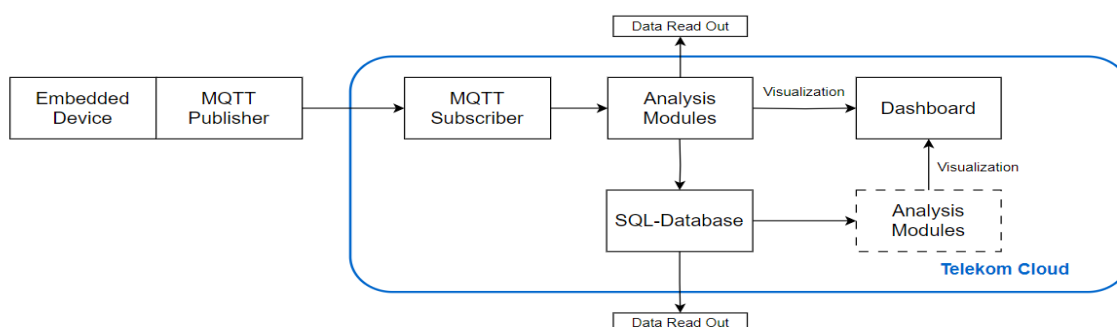


Abbildung 6 Schema der erarbeiteten Lösung für die Cloud-basierten Datenmanagement- und Analyse-Services

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). Diese sind größtenteils unabhängig von der Anzahl der Sensoren, ihrer Auflösung und Reichweite und ermöglichen eine praxisgerechte Datenübertragung und Analyse ermöglichen.

Zur Speicherung historischer Daten wurde 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.

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.

In Anlehnung an die Arbeiten in Use Case 1 konzentrierte sich LiangDao auf die Erfassung und Zählung erkannter Objekte. Der Datenstrom wurde entsprechend gefiltert und in einer SQL-Datenbank gespeichert. Sowohl Live-Daten als auch historische Daten können im Dashboard angezeigt werden.

In weiteren Tests wurde die parallele Verarbeitung und Darstellung zweier Datenströme erprobt (siehe Abbildung 2). Dabei werden sowohl Live-Daten (oben) als auch aggregierte Session-Daten (unten) visualisiert.



Abbildung 7 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).

Durch das Fraunhofer EMI wurde in Arbeitspaket 5.3 eine Hochleistungs-Workstation angeschafft. Diese wurde intensiv für Tests zur Schätzung von Ausfallraten bei der Spurerkennung mittels CARLA-Simulation eingesetzt und diente auch zur Evaluierung von Speicher- und Rechenleistung. Darüber hinaus wurde die Workstation erfolgreich für Rechenzeittests genutzt, um die Leistung mit einem Standard-Intel-i7-Laptop zu vergleichen und Optimierungsmöglichkeiten zu bewerten.

2.1.7 AP 6 – DATENAUFBEREITUNG UND VEREINHEITLICHUNG FÜR KOMMUNIKATION SZT UND CLOUD SOWIE TELEMATIK-MIDDLE-WARE (RAC)

Die RA Consulting GmbH (RAC) leitete dieses AP, welches sich mit der Realisierung einer verlässlichen Kommunikation, sowie einer Vereinheitlichung der relevanten Daten zur Validierung befasste. Im Rahmen dieses AP wurde daher die Middleware-Komponente TelTaKo-S konzipiert, sowie bestehende Standards analysiert.

Substanziell für den erfolgreichen und wirtschaftlichen Einsatz von Standards ist die Interoperabilität der Standards um Insellösungen in den Life-Cycle umfassenden Testverfahren und Tools zu vermeiden. Um diesen übergeordneten Aspekt der Standardisierung zu berücksichtigen hat die RAC aktiv an der ASAM Testspezifikation Gruppe teilgenommen. Dort wurden durch die Arbeitsgruppe, nach eingehender Analyse, Konzepte für die Interoperabilität der ASAM Standards ODS, OTX und XIL erarbeitet. Die entsprechenden Arbeiten zu drei unterschiedliche Proof-of-Concepts wurden angestossen und sollen im Nachlauf des Projektes unter Leitung der RA Consulting GmbH im Rahmen der ASAM Arbeitsgruppe umgesetzt werden.

In den folgenden Abschnitten wird beschrieben, wie die Umsetzung erfolgte, welche Aufgaben bearbeitet wurden.

Das AP 6, das sich neben der Standardisierung auf Konzept und die exemplarische Umsetzung des TelTaKo-S konzentrierte, war in mehrere Teilpakete gegliedert.

Das erste Teilpaket, UAP 6.1, befasste sich mit der Standardisierung von Szenarienbeschreibungen. Die Aufgabe bestand darin, festzulegen, wie Szenarien dargestellt werden sollten, damit sie von verschiedenen Partnern, Plattformen und Werkzeugen gleichermaßen genutzt werden können.

Das zweite Teilpaket, UAP 6.2, beschäftigte sich mit der vereinheitlichten Datenaufbereitung und Annotation. Ziel war es, Daten aus unterschiedlichen Fahrzeugen und Sensorsystemen zu harmonisieren, sodass Informationen wie Kamerabilder oder OBD-Signale konsistent abgebildet werden konnten.

Im Rahmen von UAP 6.1 und 6.2 wurden Workshops zu den relevanten Standards organisiert. Die ASAM stellte dabei Frameworks wie OpenSCENARIO, OpenDRIVE, OpenCRG, OpenODD und OpenLABEL vor. Ein Ergebnis dieser Phase war ein Katalog von Empfehlungen zur Nutzung dieser Standards im RDV-Projekt sowie ein Klassifikationsschema für Szenarien.

Im dritten Teilpaket, UAP 6.3, wurden die Kommunikationsanforderungen analysiert. Unterschiedliche Anwendungsfälle stellten jeweils verschiedene Anforderungen an Bandbreite, Latenz und Zuverlässigkeit. So konnten Telemetriedaten mit einer gewissen Verzögerung übertragen werden, während für die Fernsteuerung niedrige Latenzzeiten erforderlich waren. UAP 6.3 definierte diese Anforderungen systematisch und erarbeitete eine Taxonomie der Kommunikationsbedarfe.

Das vierte Teilpaket, UAP 6.4, entwickelte das Systemkonzept des TelTaKo-S. Dazu gehörten die Ausarbeitung der Gesamtarchitektur, die Definition der Module sowie die Spezifikation ihrer Schnittstellen. Die Architektur musste modular, skalierbar und portierbar auf unterschiedliche Cloud-Plattformen ausgelegt sein.

In UAP 6.5, lag der Fokus auf der prototypischen und komponentenbasierten Implementierung. Hierbei wurde das Architekturdesign in eine exemplarische Implementierung überführt, in der Module wie Authentifizierung, Monitoring, Aufgabenplanung und Kommunikationsmanagement integriert wurden, um grundlegende Funktionen testen zu können.

Im Rahmen des UAP 6.6 wurde die Evaluation der Ergebnisse durchgeführt. Dazu gehörten Tests der Prototypen unter realen Bedingungen, die Validierung ihrer Leistungsfähigkeit und der Abgleich mit den zuvor definierten Anforderungen.

UAP 6.7 stellte sicher, dass Ergebnisse in andere Arbeitspakete sowie in Querschnittsaktivitäten einfließen, insbesondere im Hinblick auf die Weitergabe von Ergebnissen an Standardisierungsgremien.

In AP9.1 bzw. Im Rahmen des Use Cases 4 wurden die erzielten Ergebnisse validiert.

2.1.8 AP 7 – GESAMTSICHERHEITSMODELLIERUNG UND NACHWEISBEDARFSBESTIMMUNG (EMI)

In AP 7 wurde eine datengetriebene Gesamtsicherheitsmodellierung und Nachweisbedarfsbestimmung für autonome Fahrfunktionen entwickelt, um den Nachweis- und Testaufwand zu steuern und effizienter zu gestalten. Ziel war es, ein umfassendes Simulationsmodell zu schaffen, das verschiedene Markov-Modelle einsetzte, um sicherheits- und zuverlässigkeitsorientierte Kenngrößen zu berechnen und zu bewerten sowie die Berechnungszeit der Modelle zu optimieren, um mit der Zustandsraumexplosion umgehen zu können.

In UAP 7.1 wurde eine geschachtelte, skalierende Gesamtsystem-Simulation für autonome Fahrzeuge entwickelt, die die Modellierung von Fahrzeugen, Fahrern und Verkehrsteilnehmern umfasst. Es wurden Workshops zur hierarchischen Klassifizierung von Systemkomponenten durchgeführt, und ein erweiterbares Klassifizierungssystem ermöglicht die Generierung des Gesamtzustandsraums für Markov-Modelle.

In UAP 7.2 wurden verschiedene analytisch-numerische Verfahren, einschließlich Monte-Carlo-Simulationen, für dynamische hochdimensionale Zustandsräume entwickelt und implementiert. Ein

Python-Framework ermöglicht nun eine schnelle und flexible Erstellung von Markov-Modellen, wobei die Rechenzeit durch Optimierungen signifikant reduziert wurde.

UAP 7.3 widmete sich der Einbindung von Machine Learning (ML) und Künstlicher Intelligenz (KI) zur Effizienzsteigerung der Solver und Algorithmen. Ein einfaches neuronales Netz wurde entwickelt und trainiert, um die Simulationsergebnisse zu unterstützen, und es wurden Daten für hochdimensionale Modelle generiert, um Benchmarks für die Leistungsverbesserung zu erstellen.

In UAP 7.4 wurden Zuverlässigkeits-, Sicherheits- und Effizienzkennzahlen für ein Markov-Modell ermittelt, wodurch die Wahrscheinlichkeit von Fehlerzuständen und die Gesamtzuverlässigkeit bewertet werden konnten. Die Berechnungen wurden erfolgreich auf modularisierte Modelle ausgeweitet, und entsprechende Transformationen für Fehlerparameter wurden eingeführt.

UAP 7.5 befasste sich mit der Bestimmung des Nachweisbedarfs durch Kritikalitäts- und Sensitivitätsanalysen für ein repräsentatives Übergangsmodell. Die Erfassung realer Inputdaten zu Ausfalldaten gestaltete sich als schwierig und somit wurden die Arbeiten auf Basis von mittels Literaturrecherche geschätzter Daten durchgeführt.

In UAP 7.6 wurden Workshops organisiert, um den Stand des Gesamtprojekts zu erörtern, den Austausch zwischen den Partnern zu fördern sowie die Vernetzung zu den anderen APs herzustellen. Das Fraunhofer EMI untersuchte in Zusammenarbeit mit Partnern die Möglichkeiten und Grenzen von Gesamtsystemmodellen und diskutierte relevante Ansätze zur Modellierung im Rahmen von Use Case 2.

Zuarbeit dSPACE:

dSPACE untersuchte im Rahmen von AP 7 den Einsatz von Markov-Modellen zur Bewertung wetterbedingter Auslösebedingungen. Ziel war es, unterschiedliche Ausfallraten zu analysieren und somit einen Beitrag zur Erhöhung der Sicherheit autonomer Fahrzeuge unter Berücksichtigung der SOTIF (Safety of the intended Functionality – definiert in ISO 21448) zu leisten. Die Ergebnisse zeigen, dass Markov-Prozesse einen relevanten Beitrag zur Erhöhung der Sicherheit leisten können. Sie ermöglichen eine gezielte Priorisierung kritischer Testszenarien und steigern die Effizienz bei der Absicherung automatisierter Fahrfunktionen (UAP 7.1, UAP 7.3 und UAP 7.5). Diese Aktivitäten waren Bestandteil von Use Case 2.

Zuarbeit TTTech:

Die Untersuchungen auf den Gebieten der Zuverlässigkeits- und Sicherheitskenngrößen, Verfügbarkeit, priorisierte Echtzeitfähigkeit, Rekonfiguration, Selbstdiagnose speziell unter Nutzung der Organic Computing Möglichkeiten wurden unterstützt, insbesondere in Kooperation mit dem Projektpartner JHP. Dabei wurden F&E Arbeiten im Hinblick auf die Einbindung von Markov Simulationsergebnisse für Anwendung in funktionaler Sicherheit und betreffend „compliance“ zu SOTIF Standard untersucht. Die Ergebnisse kamen dem in AP 11 aufgebauten RD Referenz System und den Auswirkungen für das automatisches AD MW & Computing Test-System in Bezug auf deren Nachweisarbeiten zugute.

2.1.9 AP 8 – XIL-SIMULATION (dSPACE)

Der SiL- Simulationsansatz erfordert die Auswahl adäquater Testmethoden und Testumgebungen und muss auf verschiedenen Systemebenen und mit unterschiedlichem Detaillierungsgrad durchgeführt werden. Der Simulationsansatz gliedert sich grundsätzlich in die Schritte Testvorbereitung, Testdurchführung und Testauswertung. In AP 8 wurden insgesamt zwei unterschiedliche Aktivitäten durchgeführt.

Zum einen wurde die Validierung eines Vehicle-Dynamics-Fahrzeugmodells durchgeführt. Ziel dieser Maßnahme war es, nachzuweisen, dass das virtuelle Modell zuverlässig ist und das Verhalten des realen Fahrzeugs realistisch abbildet. Der Validierungsprozess folgt den zuvor beschriebenen Schritten des

Simulationsansatzes – von der Testvorbereitung über die Testdurchführung bis hin zur Testauswertung. Ein erfolgreich validiertes Modell kann anschließend als Input für weitere virtuelle Tests genutzt werden, da in der Testvorbereitung Modelle entsprechend einer vorgegebenen Testspezifikation erstellt und eingesetzt werden müssen. Die Aktivitäten wurden im Rahmen von Use Case 3 durchgeführt.

Zusätzlich wurden in AP8 die bereitgestellten Kamera- und LIDAR-Daten genutzt, um einen dSPACE internen, kamerabasierten Perzeptionsalgorithmus und einen von Liangdao bereitgestellten lidarbasierten Perzeptionsalgorithmus mittels Data Replay zu testen. In der Testvorbereitung mussten die erforderlichen Simulationsartefakte erstellt und die notwendigen Tools für die Integration und Ausführung der Data-Replay-Tests eingerichtet werden. Während der anschließenden Testdurchführung wurden Simulationsläufe mit jeweils einem neuen Perzeptionsalgorithmus durchgeführt. Bei der Testauswertung wurden Key Performance Indikatoren (KPIs) genutzt, um die Simulationsergebnisse zusammenzufassen und daraus übergeordnete Informationen zu gewinnen. Das Vorgehen und die Ergebnisse wurden im Rahmen von Use Case 1 umgesetzt und erstellt. Die Bereitstellung der notwendigen Sensordaten, Perzeptionsalgorithmen und die statistische Auswertung werden in AP 1 und AP 3 beschrieben.

2.1.10 AP 9.1 – TESTFAHRTEN AUF DEM TESTFELD AUTONOMES FAHREN BADEN-WÜRTTEMBERG MIT INTEGRIERTEM TELTAKO-S UND LEITSYSTEM TAF (RAC)

Der Ansatz nach Wegfall der HORIBA-Prüfstandes die Testfahrten im TAF durchzuführen konnte aufgrund der fehlenden Förderzusage für die erhöhten Kosten, die mit der Nutzung des TAF verbunden sind, im Projekt nicht durchgeführt werden. Aus diesem Grund wurden im Ersatz für die Prüfstandsanzbindung Testfahrten mit einem begrenzt autonom fahrenden mobilen Transportfahrzeug auf dem nichtöffentlichen Gelände der RAC und mit zwei nicht autonom fahrenden Testfahrzeugen auf öffentlichen Straßen in Verbindung mit einem integrierten TelTaKo-S und einem RAC-Controlpanel durchgeführt.

Dabei wurden die wesentlichen Anforderungen, die für die Kommunikation mit dem Fahrzeug aus der Validierung der Zielfunktionen, soweit abbildbar, realisiert. Zunächst wurden grundlegende, zu validierende Funktionen selektiert, die dann mit einem geeigneten Aufbau validiert werden konnten.

Es konnten Testfahrten mit verschiedenen, eigens für die Validierung ausgerüsteten Fahrzeugen in Kombination mit einer entsprechenden bidirektionalen Kommunikation über den TelTaKo-S realisiert werden.

Hierzu wurden terrestrische und nicht-terrestrische Kommunikationstechniken (4G, 5G, Wifi und StarLink) untersucht und im Feld getestet. Für die terrestrische Kommunikationstechnologie 5G konnte sich RAC erfolgreich für ein Pilotprojekt der Telekom qualifizieren, in dem eine API zur Einstellung des QoS für 5G-Dienste im Feld erprobt wurde. Auf Basis der Ergebnisse der Feldversuche konnte eine Bewertung erfolgen und Handlungsempfehlungen zu den Nutzungsbereichen der einzelnen Kommunikationstechniken gemäß dem im Projekt erarbeiteten Anforderungsklassifikationsschema für die Kommunikation erstellt werden.

Die entsprechenden Ergebnisse in diesem Arbeitspaket, sowie auch die Validierung der exemplarischen Entwicklung TelTaKo-S aus AP 6 erfolgte im Rahmen von Use-Case 4.

2.1.11 AP 9.2 – AUFBAU UND INTEGRATION FORSCHUNGSFAHRZEUG / PROVING GROUND (THA)



Abbildung 8: Versuchsträger auf dem Testgelände

Im Rahmen des Arbeitspakets wurden die relevanten Systemkomponenten und Schnittstellen abgestimmt, funktionale und nicht-funktionale Anforderungen definiert und die zugrunde liegenden Datenstrukturen modelliert. Die Ergebnisse mündeten in einer konsistenten Systemspezifikation, die zugleich als Grundlage für die Markov-Modellierung des System- und Umgebungsverhaltens diente.

Das Forschungsfahrzeug, ein Leichtbau-Shuttle der Firma Inyo, wurde im Juni 2024 erstmals ausgeliefert und nach einer umfassenden Begutachtung durch das THA-Team überarbeitet. Nach der Behebung identifizierter Mängel in Mechanik, Elektrik und Sicherheitsfunktionen erfolgte im Januar 2025 die erneute Auslieferung. Anschließend wurde das Shuttle im Technologie-Transfer-Zentrum (TTZ) Landsberg vollständig für den automatisierten Betrieb vorbereitet. Hierzu zählten die Anpassung der Bordelektronik, die Inbetriebnahme der Aktuatoren, der Aufbau von Dach- und Rackträgern für Sensorik und Rechner, die Integration von Kameras, LiDARs, Radar, GNSS und HMI sowie die Absicherung der Spannungsversorgung und Kommunikation.

Da das Shuttle keine Straßenzulassung besitzt, wurde ein zusätzliches, straßenzugelassenes Fahrzeug als Datensammler mit identischer Sensorik ausgerüstet. Damit wurden über 400.000 Sensordatenframes in unterschiedlichen urbanen Gebieten Augsburgs und Landsbergs aufgezeichnet. Die Daten wurden manuell annotiert und dienten der Entwicklung und Validierung der Wahrnehmungsalgorithmen. Die verbesserte Version V1 der Wahrnehmungskomponenten wurde anschließend in das Shuttle integriert und am Vehicle-in-the-Loop-Prüfstand erfolgreich evaluiert.

Parallel erfolgte die Integration und Weiterentwicklung des autonomen Software-Stack. Nach Abschluss der Systemplanung wurden sämtliche Komponenten installiert, konfiguriert und getestet. Kompatibilitätsprobleme mit externen Perzeptionsalgorithmen machten eine Umstellung auf interne Entwicklungen erforderlich. Die Kommunikation zwischen der Steuerungseinheit (dSpace MABX-2), den

Aktuatoren und den Sensoren wurde erfolgreich umgesetzt. Darüber hinaus konnten neue Radarsysteme und Solid-State-LiDARs in das ROS2-Kommunikationsframework eingebunden und hinsichtlich Datenqualität und Zuverlässigkeit optimiert werden.

Damit wurde eine stabile technische Grundlage geschaffen, auf der die Validierung der entwickelten Algorithmen sowie die geplanten Testkampagnen im Testzentrum Penzing fortgeführt werden können.

2.1.12 AP 10 – PROZESS ZUM SICHERHEITSNACHWEIS IM ENTWICKLUNGSZYKLUS FÜR HOCHAUTOMATISIERTE FAHRZEUGE (THA)

Das Forschungsfahrzeug wurde entsprechend den Projektzielen konzipiert und mit allen sicherheitsrelevanten Komponenten ausgestattet. Die Degradations- und Sicherheitskonzepte wurden abgestimmt, in die Fahrzeugarchitektur integriert und für Fault-Injection-Tests vorbereitet.

Ein zentrales Ergebnis ist das implementierte Sicherheitskonzept für den autonomen Fahrbetrieb. Es ermöglicht dem Sicherheitsfahrer jederzeit einen manuellen Eingriff über drei redundante Abschaltwege: Betätigung des Bremspedals, Aktivierung eines Not-Aus-Knopfes oder Lenkradeingriff. Letzterer wird über einen Drehmomentsensor erfasst, dessen Signale softwareseitig ausgewertet werden. Bei Überschreiten eines Schwellwerts erfolgt die sofortige Deaktivierung des autonomen Modus. Messungen bestätigten eine Reaktionszeit von rund 100 ms und damit eine praxisgerechte, hochzuverlässige Eingriffslogik.




Abbildung 9: Realer Betrieb und virtuelles Szenario

Zur methodischen Absicherung der Fahrfunktionen wurde das **Hybrid Testing Framework (HTF)** entwickelt, das reale Fahrdaten mit virtuellen Testszenarien kombiniert. Es erlaubt die gezielte Injektion simulierter Objektlisten in den realen Softwarestack und bildet so eine Brücke zwischen Simulation und Fahrzeugbetrieb. Vergleichsstudien mit verschiedenen LiDAR-Sensormodellen zeigten, dass das Fixed-Angle-Modell die höchste Übereinstimmung mit realen Punktwolken erreicht und sich daher für die Validierung der Perzeptionsalgorithmen besonders eignet.

Das HTF koppelt den Fahrzeugrechner über eine MQTT-basierte Middleware mit einem Simulationsrechner, auf dem CARLA 0.9.15 ausgeführt wird. Eine eigens entwickelte „Real2Sim“-Node erzeugt auf Basis der Fahrzeugdaten einen digitalen Zwilling in Echtzeit, wodurch Sensordaten und Objektlisten konsistent zwischen realer und virtueller Umgebung ausgetauscht werden können. Damit entsteht eine flexible und übertragbare Plattform für hybride Testszenarien und Sicherheitsanalysen.

Zuarbeit TNM:

Auf Basis eines Fahrzeugs, welches teilautonome Fahrfunktionen aufweist, bestand die Aufgabe von TÜV NORD Mobilität darin, Anforderungen zu entwickeln, mit denen eine Typprüfung von autonom agierenden Fahrzeugen erfolgen und unter den zu Berücksichtigten Homologationskriterien validiert werden kann. Dazu sollten auch der durchgeführte Test und Handlungsempfehlungen evaluiert werden.

Zuarbeit von TTTech:

Im Rahmen von AP 10 wurde ein Software-Modul für das automatische AD MW Test-System erzeugt, das die Automatisierung der Test-Szenarios unterstützt. Damit wurde die Möglichkeit geschaffen, einen automatischen Testablauf in einem integrierten Gesamtsystem sowohl für Systemteile, wie der MW, als auch für das Gesamtsystem zu unterstützen.

2.1.13 AP 11 – ERFORSCHUNG UND BEITRÄGE FÜR DIE NÄCHSTEN GENERATIONEN AD SYSTEME SAE LEVEL 4&5, REFERENZSYSTEM UND AUTOMATISCHES TESTEN (TTTECH)

Im Arbeitspaket AP 11 hat sich TTTech in Kooperation mit den Projektpartnern auf die Aufgabe konzentriert, eine Architektur für eine Implementierung von SAE Level 4-5 Fahrzeugen (hoch-automatisierte bzw. Autonome Fahrzeuge, „autonomous driving“, AD) sowie den Aufbau eines entsprechenden AD Referenzsystems inklusive eines automatischen AD MW & Computing Test Systems zu erarbeiten. Da derartige Systeme aus heutiger Sicht bei weitem noch nicht in Serienreife existieren (trotz Konzepten wie dem Robotaxi von Waymo bzw. einschlägigen Ansätzen von Tesla, die in den Breiten mit all den widrigen Wetterbedingungen auch noch deutliche Herausforderungen haben), wurden diese Schwerpunktentwicklungen in einem Laboraufbau realisiert (TRL 4-5).

Eine wesentliche Komponente war dabei die Untersuchungen in Kooperation mit dem Projekt SafeAutoDoc ([FKZ 19A21044A](#)) und der dort entwickelten Technologie „Organic Computing“ in echtzeitgesteuerten Systemen. „Organic Computing“ wurde dabei zur automatischen Fehlerkorrektur und zum Erstellen eines permanent aktualisierten „Gesundheitszustandes“ eines eingebetteten Systems („embedded System“) erstmals praktisch eingesetzt.

Dabei gab es folgende Unterarbeitspakete:

UAP 11.1: Es wurde ein Pflichtenheft und eine Spezifikation für das AD Referenzsystem für „Organic Computing“ in der nächsten Generation Fahrzeuge erstellt.

UAP 11.2: Entwicklung und Aufbau des AD Referenzsystem gemäß Pflichtenheft aus UAP 11.1. Zusätzlich wurde eine Spezifikation der Testparameter für den Aufbau des automatischen AD MW & Computing Test Systems entwickelt.

UAP 11.3: Integration der HW Komponenten der AD Referenzsystems mit den MW & SW Modulen inklusive der „Service oriented Architecture“ (SoA) Module und den „Organic Computing“ basierten Funktionen, das für die Selbst-X Eigenschaften (Selbst-Organisation, Selbst-Konfiguration, Selbst-Optimierung, Selbst-Heilungseffekte bei Störungen und Fehlern) eingesetzt und untersucht wurde.

UAP 11.4: Die Testaufbauten zur Verifizierung der Funktion des AD Referenzsystems wurden in diesem UAP entwickelt.

Gemeinsamer Schlussbericht

Donnerstag, 18. Dezember 2025

Seite 38 von 75

UAP 11.5: HW/SW seitige F& E Arbeiten und Entwicklung des automatische AD MW & Computing Test Systems

UAP 11.6: Integration des AD Referenzsystems mit dem automatischen AD MW & Computing Test System und schrittweise Durchführen der notwendigen Tests zum Nachweis der Funktion gemäß Pflichtenheft und Spezifikationen um die Leistungsfähigkeit des Gesamtsystems zu untersuchen und zu verifizieren. Dabei war ein wesentlicher Schwerpunkt der gesamten Entwicklung in AP 11 zu untersuchen, inwieweit speziell die Organic Computing Module und die SoA im Einklang mit einer echtzeitfähigen TTEthernet/TSN Datenkommunikation arbeiten können. Die Untersuchungen und entwickelten Modelle aus AP 3 haben wertvolle Indikationen bei der Erarbeitung der Tests zur Verifikation gegeben.

UAP 11.7: Dieses UAP beschäftigte sich mit den Tests und der Verifikation des automatischen AD MW & Computing Test Systems gemäß Pflichtenheft und Spezifikation (analog zu noch vor der Integration durchgeführten Arbeiten in UAP 4 für das AD Referenzsystem).

UAP11.8: Das Arbeitspaket betraf lediglich diverse Zuarbeiten zu anderen APs wie AP 0 (Architekturüberlegungen für den Up-/ Down-Link), und unterstützende Arbeiten für AP 3 (Informationsaustausch für Beispielmuster und Beispiel-Parametern zu den Simulationsmodellen, die von Projektpartnern entwickelt wurden) und für AP 7 (betreffend Simulation).

Anmerkung zur Entwicklung des AD Referenzsystems durch TTTech: Im Zuge der durchgeführten Tests des AD Referenzsystems wurde festgestellt, dass die benötigten Computing Ressourcen mit sehr hohen HW Kosten für hoch leistungsfähige Mikrokontroller verbunden sind. Um das Problem der vergleichsweise hohen HW Kosten zu reduzieren, wurde ein SW basiertes Accelerator System bestehend aus zwei SW Komponenten, dem TT-Executer und dem TT-Orchstrator vorerst als Simulation (quasi als initiale Machbarkeitsstudie) und später in einer Implementation der entsprechenden SW Module entwickelt. Ziel der ursprünglich nicht geplanten F&E Arbeiten war es, mit weniger leistungsfähigen Mikrocontrollern dennoch ein gutes AD Ergebnis erreichen zu können. Entsprechende Grafiken zu der Implementierung sind in der Beschreibung von UC 5 enthalten.

AP 11 Arbeiten von dSPACE:

Im Arbeitspaket AP11 lag ein Schwerpunkt auf der Erforschung und Entwicklung von Beiträgen für die nächsten Generationen automatisierter Fahrsysteme (SAE Level 4 und 5). Ein zentraler Beitrag war die gemeinsame Erarbeitung einer Fachveröffentlichung (V11) mit JHP, die einen statistischen Ansatz zur Quantifizierung der Auftretensrate bislang unbekannter Szenarien behandelte. dSPACE brachte seine Expertise in der Validierung und Simulation ein, während JHP die statistische Modellierung und Auswertung übernahm. Thematisch ist diese Tätigkeit primär in AP11 zu verorten. Durch die angewandten statistischen Methoden ergaben sich jedoch zugleich Schnittstellen zu AP 3.

Um den Anforderungen an der Validierung und Absicherung von Fahrerassistenzsystemen (ADAS) und autonomen Fahrfunktionen (AD) in modernen Fahrzeugen gerecht zu werden, müssen Szenarien, die im realen Straßenverkehr auftreten können, systematisch erfasst und bewertet werden. Mit einem statistischen Ansatz lässt sich die Auftretensrate potenziell risikobehafteter, neuer Szenarien quantifizieren. Die Betrachtung unbekannter Szenarien ist insbesondere im Kontext von SOTIF von hoher Relevanz, da diese nicht durch klassische Testmethoden vollständig erfasst werden können. Die Ergebnisse wurden im Rahmen von Use Case 3 bearbeitet.

2.1.14 USE CASE STRUKTUR

Wie bereits in Kapitel 1.3 beschrieben, wurde zur besseren Übersicht und zielgerichteten Bearbeitung das Projekt während der Projektlaufzeit in fünf Use Cases unterteilt. Jeder Use Case adressiert spezifische Anforderungen und Fragestellungen innerhalb des Projekts. Die Use Cases und die damit zu bearbeitenden Fragestellungen sind in der Abbildung 10 dargestellt. Nachfolgend werden jeweils die Ergebnisse der Use Cases 1-5 beschrieben.

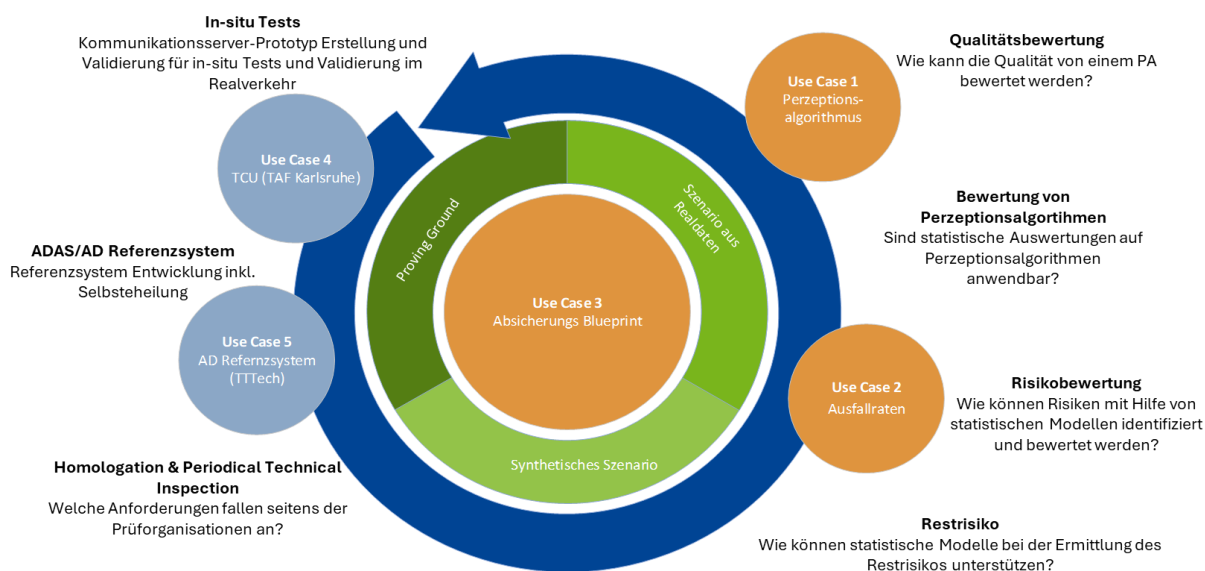


Abbildung 10: Use Case 1-5

Use Case 1: Perception Testing

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 Beantwortung dieser Fragen wurde der von LiangDao bereitgestellte Perzeptionsalgorithmus untersucht. Hierzu wurden drei unterschiedlich oft trainierte Algorithmen zur Verfügung gestellt, die mittels Data Replay in einer Software-in-the-Loop Umgebung (open loop) getestet wurden. Demnach wurden zuvor aufgenommene Sensordaten (Lidar Punktwolke) in das Device Under Test (Perzeptionsalgorithmus) eingespeist. Ergänzend dazu hatte IQZ die Sensordaten gezielt manipuliert, um zusätzliche Varianz und Erweiterung in die Datengrundlage zu bringen. Anschließend wurde die Reaktion des Perzeptionsalgorithmus im Vergleich zu Referenz- oder Ground-Truth-Daten bewertet. Für die Bewertung wurden KPI-Level und Typen definiert. Anschließend wurde mittels statistischer Hochrechnung geprüft, ob ein Reifegrad bestimmbar ist und eine Prognose für diesen abgegeben werden kann. Abbildung 11 verdeutlicht die beschriebenen Zusammenhänge und stellt die Partnerbeiträge dar.

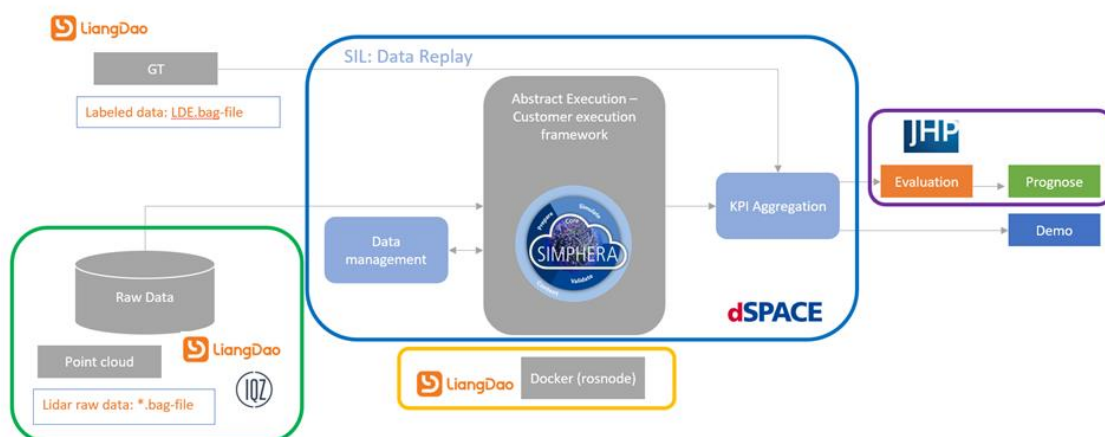


Abbildung 11: Überblick zu Use Case 1

LiangDao: Wie in der Einleitung beschrieben, basierten die Arbeiten im Use Case 1 auf drei speziell für die Projektanforderungen trainierten LiangDao-Perzeptionsalgorithmen. Diese wurden jeweils mit Sensordaten aus den Umgebungen *Autobahn* und *Stadtverkehr* trainiert – in drei unterschiedlichen Trainingsumfängen: 2 %, 60 % und 100 % 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. 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.

IQZ: Im Rahmen des Use Case 1 wurde durch das IQZ ein Modul in Matlab entwickelt, welches die nachträgliche Manipulation von Sensordaten ermöglicht. Diese Manipulation hat das Ziel, die Robustheit des Perzeptionsalgorithmus hinsichtlich der Qualität der zugrunde gelegten Sensordaten zu überprüfen und Schwachstellen aufzuzeigen. Die Sensordaten werden dem Modul in Form eines rosbag übergeben. Anschließend werden die Daten der Punktwolke aus dem rosbag extrahiert und manipuliert. Abschließend werden die Daten zurück in ein rosbag geschrieben und können in der Software-in-the-Loop-Umgebung von dSPACE verwendet werden.

Die Mechanismen, welche hierbei für die Manipulation herangezogen wurden, beruhen einerseits auf Sensor-internen Aspekten, wie der Datenverlust aufgrund von Übertragungsfehlern, andererseits wurde die Verschlechterung von Sensordaten aufgrund von externen Einflüssen, am Beispiel der Sensorkontamination, berücksichtigt.

Bei den Sensor-internen Aspekten wurden drei unterschiedliche Mechanismen implementiert, welche in ihrer Intensität im Rahmen der Manipulation angepasst werden können:

1. Das zufällige Ändern von Datenpunkten in allen drei Dimensionen innerhalb des Field-of-Views auf Basis von eingegebenen Wahrscheinlichkeiten.
2. Der Verlust von Datenpunkten auf Basis von eingegebenen Wahrscheinlichkeiten.

3. Manipulation der Datenpunkte unter Verwendung eines Rauschens (Noise), welches über die Punktwolke gelegt wird. Die Intensität des Rauschens kann hierbei über die Anzahl an hinzugefügter Datenpunkte angepasst werden.

Abbildung 12 zeigt beispielhaft den Datenpunktverlust eines Simulationsframes.




Abbildung 12: Datenpunktverlust, links Original, rechts 50% Verlust

Die Sensorcontamination wurde mit Hilfe des Perlin Rauschens umgesetzt. Das Perlin Rauschen zeichnet sich dadurch aus, dass es kein gleichverteiltes Rauschen ist, sondern sich Strukturen ausbilden, die Wolken oder Wasser ähneln, wodurch sie wiederum geeignet dazu sind, die Verschmutzung eines Sensors nachzubilden. In Abbildung 13 ist die schematische Anwendung des Perlin Noises skizziert.

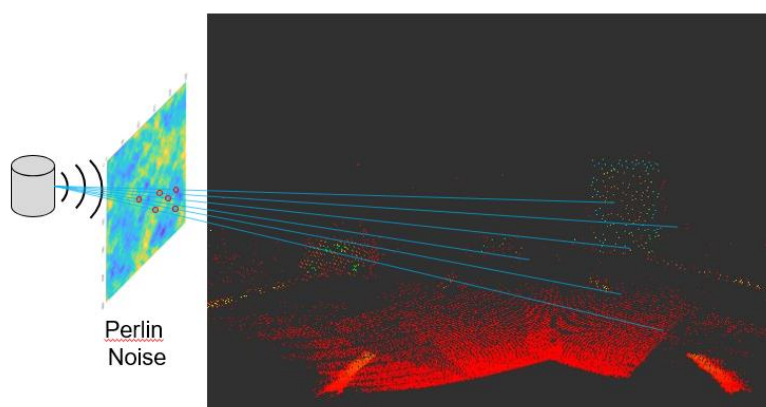


Abbildung 13: Schema der Punktwolkenmanipulation mit Perlin Noise

Für die Ausprägung der Senordatenmanipulation ist die Definition von zwei Parametern (`val_low`, `val_high`) notwendig, welche mit den Werten aus dem Rauschen abgeglichen werden. Der Parameter `val_low` definiert die Grenze, ab wann die Verschmutzung Auswirkungen auf die Daten hat. Liegt der Wert des Rauschens zwischen den Parametern `val_low` und `val_high`, wird die Reichweite des Sensors linear mit steigendem Wert eingeschränkt. Liegt der Wert über dem Parameter `val_high` können keine Objekte in diesem Bereich detektiert werden.

Mit Hilfe des beschriebenen Manipulationsmechanismus konnte in dem UC1 gezeigt werden, dass eine nachträgliche Bearbeitung von Sensordaten zur Überprüfung der Robustheit von Perzeptionsalgorithmen möglich ist.

dSPACE: Nach der Bereitstellung der Daten durch LiangDao und IQZ konzentrierten sich die Aktivitäten auf das Testen der lidarbasierten Perzeptionsalgorithmen mittels Data Replay in einer Software-in-the-Loop-Umgebung und der Bewertung der Algorithmen anhand definierter Key Performance Indikatoren (KPI) durch dSPACE.

Der Simulationsansatz gliederte sich in die Phasen Testvorbereitung, Testdurchführung und Testauswertung. Zunächst wurden die bereitgestellten Perzeptionsalgorithmen in die cloudbasierte

Lösung SIMPHERA integriert. Anschließend erfolgten die Simulationsläufe. Dazu wurden die zur Verfügung gestellten Szenarien und manipulierten Daten in die integrierten Algorithmen eingespeist. In der Auswertungsphase wurden die Ergebnisse durch die KPI Precision, Recall und F1-Score bewertet.

Abbildung 14 veranschaulicht beispielhaft die Resultate der Testdurchführung eines Stadt-Szenarios unter Verwendung des Perzeptionsalgorithmus mit 60 % Trainingsumfang. Für die statistische Analyse wurden 396 Datenpunkte in 44 Frame-Blöcke zu je 9 Frames unterteilt. Die Ergebnisse wurden innerhalb des Konsortiums geteilt und von JHP für weiterführende statistische Auswertungen genutzt.

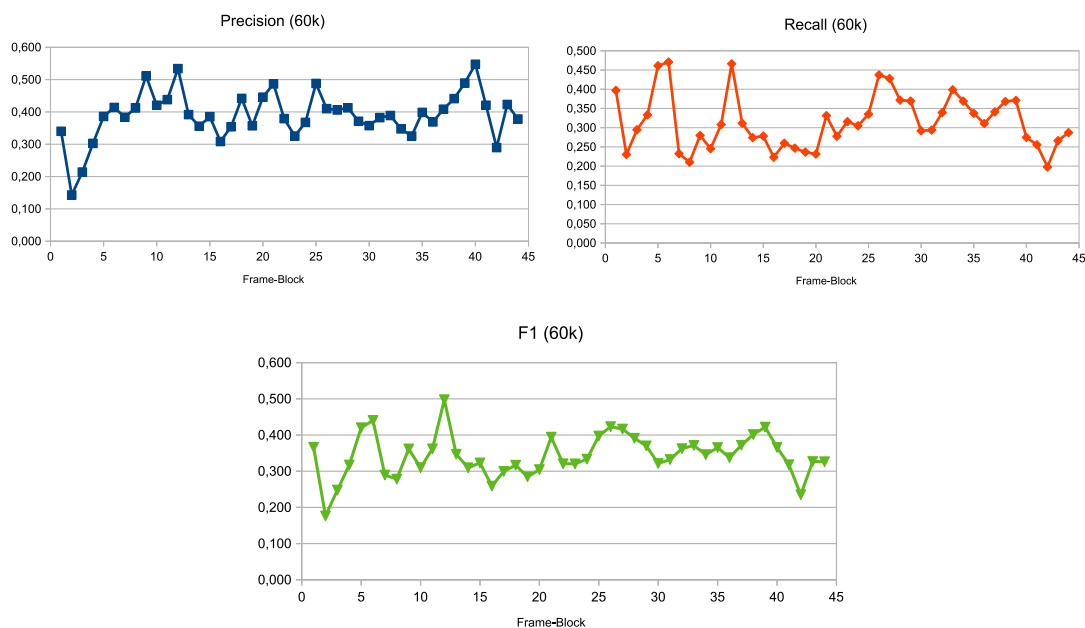


Abbildung 14: Exemplarische Auswertung - Perzeptionsalgorithmus mit 60% Trainingsumfang

Zusätzlich hatte dSPACE mit einem Versuchsträger kamerabasierte Daten aufgezeichnet, um einen internen kamerabasierten Perzeptionsalgorithmus mittels Data Replay zu testen. Anhand der gewonnenen Erkenntnisse aus diesem Test konnte dSPACE den Perzeptionsalgorithmus dahingehend verbessern, dass Szenarien wie Einscheren erkannt wurden.

JHP: Basierend auf den Validierungsdaten dreier unterschiedlicher Trainingsstände von KI-Perzeptionsalgorithmen führte JHP anhand der Gütekriterien "Precision" und "Recall" statistische Bewertungen der unterschiedlichen Trainingsstände durch. Hierzu wurden Validierungsdaten aus verschiedenen ODDs verwendet (Stadt- und Autobahnverkehr) und auch mit Perlin-Noise beaufschlagte Daten verwendet. Anhand der Gesamtdaten konnte aufgezeigt werden, dass die Streuungen der Gütemaße normalverteilt sind, woraus auswertungstechnisch ein großer Vorteil entsteht. Es ließ sich zeigen, dass die Gütemaße mit steigendem Training besser werden. Hierbei konnte aber gezeigt werden, dass die Gütemaße "Precision" und "Recall" nicht vollständig korrelieren und dass es bei einem der Maße schon zu Sättigungserscheinungen kommen kann, während das andere von weiterem Training noch stark profitiert. Anhand der verzerrten Daten konnte überprüft werden, ob Robustheit vorliegt gegenüber dem angewendeten Grad der Verzerrung durch Perlin-Noise. 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.

Use Case 2: Ausfallraten, Markov Modellierung

Use Case 2 hatte das Ziel, die Markov-Modellierung demonstrativ anzuwenden, um die Ausfallraten von Fahrzeugen unter Berücksichtigung von Umweltbedingungen und Fahrsituationen zu analysieren. Die Modellierung berücksichtigte sowohl hardware- als auch softwareseitige Ausfallraten, um fundierte Aussagen über die Zuverlässigkeit des Fahrzeugs und seiner Teilfunktionen zu treffen. Abbildung 15 zeigt einen Überblick zu Use Case 2 und die Zusammenarbeit der Partner im Use Case.

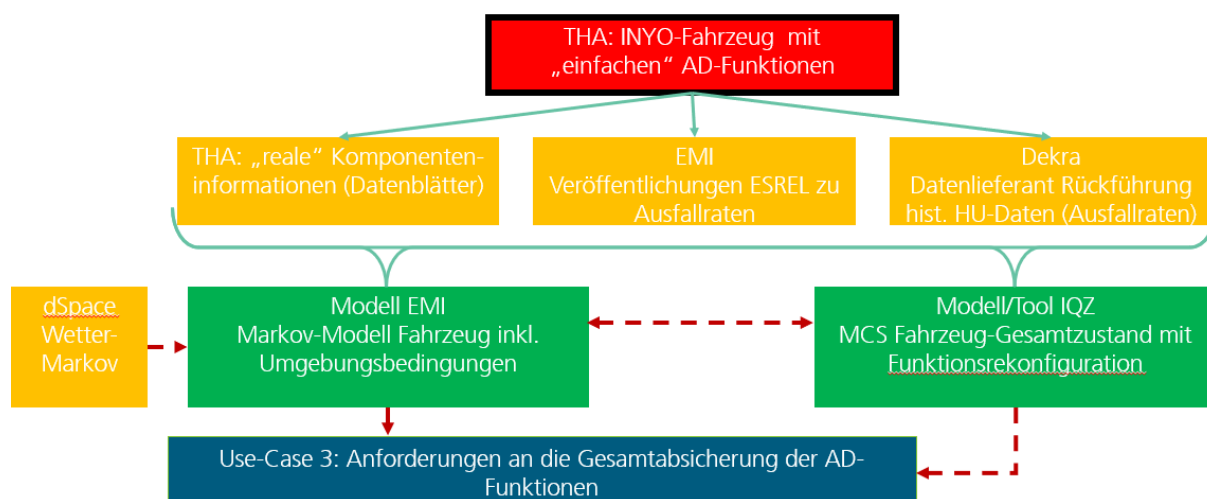


Abbildung 15: Überblick zu Use Case 2

Im Rahmen dieses Use Case bildete das INYO-Fahrzeug, ausgestattet mit „einfachen“ autonomen Fahrfunktionen, einen Ausgangspunkt.

Die DEKRA lieferte historische HU-Daten zu Ausfallraten, während die Technische Hochschule Augsburg (THA) reale Komponenteninformatoren bereitstellte. Das IQZ stellte mit dem simulationsbasierten Auswertungstool RT-CARS eine alternative Möglichkeit zur Fahrzeugmodellierung und -evaluation inkl. verschachtelter Hardware und Software Strukturen, jedoch exklusive Wettermodellierung, bereit. Dabei lag das Ziel in einer gegenseitigen Verifikation der Modelle, zwischen EMI und IQZ.

Es fanden regelmäßige Absprachen mit den Projektpartnern zum Use Case 2, insbesondere mit der THA zur Sensorik des Fahrzeugs für das Testgelände und mit IQZ zur Schnittstellendefinition zwischen dem RT-CARS-Simulationstool von IQZ und der Markov-Modellierung des EMI sowie mit der DEKRA zur Bestimmung von Ausfallraten auf Basis ihrer HU-Datenbank.

Weiteren Input lieferte die Wettermodellierung von dSPACE. Es wurde angenommen, dass Wetterbedingungen Risiken auslösen können. Ziel war es, die Eintrittswahrscheinlichkeit eines potenziellen Risikos gemäß SOTIF mithilfe von Markov-Modellen zu bestimmen und das Vertrauen in die Sicherheit des Systems zu erhöhen.

Das Modell durch das EMI beinhaltete eine Markov-Modellierung des Fahrzeugs unter Berücksichtigung von Umgebungsbedingungen, um den Gesamtzustand des Fahrzeugs und von Teilfunktionalitäten zu analysieren und zu bewerten. Zentraler Bestandteil war die Anwendung der Markov-Modellierung unter Berücksichtigung von Umweltbedingungen und Fahrsituationen. Hierbei galt es die Zustandsraumexplosion in den Griff zu bekommen sowie die Auswirkungen verschiedener Umweltbedingungen wie Wetterereignisse auf die Sensorik des Fahrzeugs zu modellieren.

Zusätzlich wurde die Verwendung von Deep-Learning-Modellen untersucht, um die Berechnungen der Markov-Modelle zu beschleunigen und so den Flaschenhals in der Datenverarbeitung zu beseitigen. Die Benchmarking-Ergebnisse zeigten, dass sowohl Multilayer Perceptrons (MLP) als auch Convolutional

Neural Networks (CNN) eine hohe Effizienz bei der Nachbildung der Funktionalität von Markov-Ketten aufwiesen.

Insgesamt zielte Use Case 2 darauf ab, die Zuverlässigkeit und Ausfallwahrscheinlichkeiten von Fahrfunktionen zu analysieren und gleichzeitig die Herausforderungen der Zustandsraumexplosion zu bewältigen. Die Resultate wurden in wissenschaftlichen Veröffentlichungen und Masterarbeiten dokumentiert und trugen zur Entwicklung branchenübergreifender Lösungen bei, die auch für Versicherer von Bedeutung sein könnten.

Im Folgenden sind die Beiträge der einzelnen Partner zum Use Case genauer beschrieben.

IQZ: Die C++/Qt basierte Softwareapplikation „RT-CARS“ zur Sicherheits- und Zuverlässigkeitsevaluation kritische Systeme ist im Rahmen von UC2 weiterentwickelt worden. RT-CARS simuliert dabei Ausfallzeitpunkte der modellierten Komponenten unter Anwendung der Monte-Carlo und unter Berücksichtigung von Fehlermanagement-Prozessen. Durch die simulative Evaluation entfällt bei dieser Methode das Problem der Zustandsraumexplosion, jedoch verschlechtert sich die Ergebnisgenauigkeit potentiell im Vergleich zu analytischen Methoden (abhängig von der Anzahl der durchgeführten Iterationsläufe, gemäß dem Gesetz der großen Zahlen). Bisher präsentierte sich das Herzstück der Evaluation als eigenständige Matlab Implementierung mit JSON (Text) basierter Eingabe zur Systembeschreibung, welches zur Steigerung der Effizienz der Simulation, als auch der Flexibilität in Sachen Auswertungsmöglichkeiten, in C++ Code überführt wurde. Damit ist ein stand-alone Programm inklusive einer selbsterklärenden, grafischen Benutzeroberfläche entstanden.

Modellverifikation

Bei der Modellverifikation sollten zunächst beide Modelle (RT-CARS und das Markov-Modell vom EMI), die *gleiche* Eingebearchitektur eines autonomen bzw. automatisierten Fahrzeuges modellieren und auswerten. Das Ziel war es zu überprüfen, ob beide Modelle grundsätzlich ähnliche Ergebnisse liefern. Auf Grund ihrer offensichtlichen semantischen Unterschiede sind Abweichungen der Ergebnisse allgemein zu erwarten, jedoch sollten grundlegende Sicherheits-KPIs wie die Zuverlässigkeit oder die Verfügbarkeit des Systems gleich oder sehr ähnlich ausfallen.

Dafür wurde sich zunächst auf die Teilarchitektur eines autonomen bzw. automatisierten Fahrzeuges abstrahiert auf den Sensor-HUB mit Anbindung an einen Fahrzeug Computer geeinigt. Der Sensor-HUB besteht aus diversen Perzeptionssensoren (5 Kamerasensoren und 4 LIDAR Sensoren). Durch unterschiedliche Positionen und Ausrichtungen im Fahrzeug entstehen unterschiedliche Redundanzdefinitionen der Sensoren. So ist beispielsweise das Haupt-LIDAR in jeglicher Situation unverzichtbar, während das Front-Lidar rechts als redundant zu erachtende Daten zur Front-Kamera rechts liefert. Folglich kann das System mit einzelnen Sensorfehlern umgehen und bleibt, je nach dem welcher Sensor ausgefallen ist, funktionsfähig. Für jede modellierte Komponente ist eine Fehlerrate (Ausfallwahrscheinlichkeit) festgelegt worden.

In einem ersten Vergleichsdurchlauf konnte gezeigt werden, dass beide Modelle (RT-CARS mit Monte-Carlo Methode und Markov Modell) sehr ähnliche Daten liefern – damit wird dieser erste Vergleich als erfolgreich angesehen. Im nächsten Schritt sollte das modellierte System um die Reparatur von Sensoren erweitert werden. So könnte beispielsweise dargestellt werden, dass ein Sensorfehler nur temporär anhält. Dies ist zwar aus Sicht der funktionalen Sicherheit ohne einen Werkstattaufenthalt nicht sinnvoll anzunehmen, könnte aber ggf. genutzt werden, um transiente Fehler, wie die temporäre Blockade durch Verschmutzung, widerzuspiegeln. Da RT-CARS zunächst Komponentenreparaturen ausschließlich mit dem auf Software spezifizierten FDIRO Prozess darstellen konnte, sind für einen weiterführenden Vergleich der Modelle Hardware-Reparaturen implementiert worden. Auf Grund der Unterschiede zu Softwarefehlern, sind bei der Hardwarefehlermodellierung lediglich zwei interne Zustände angenommen

worben (failed – active). Das damit um Reparaturmöglichkeiten erweiterte Beispielmmodell wurde ausgewertet und mit den Ergebnissen des Markov Modells verglichen.

Hier sind zunächst Unstimmigkeiten aufgefallen, die nach eingehender Analyse auf die Qualitätsannahmen einer reparierten Komponente zurückzuführen waren: In RT-CARS wird eine Hardware-Reparatur wie eine totale Reparatur bspw. durch einen Komponentenaustausch modelliert (Annahme aus der funktionalen Sicherheit), während in der Markov Modellierung die Reparatur als Reaktivierung der Komponente implementiert ist. Folglich, setzt sich in RT-CARS die Lebenszeit der Komponente, und damit auch die Wahrscheinlichkeit für nachfolgende Ausfälle, auf den Ausgangszustand zurück während in der Markov Modellierung die Lebenszeit vom Ausfallzeitpunkt wieder aufgenommen wird. Die nachstehende Abbildung 16 zeigt Reliability von dem RT-CARS Modell. Nach 10000 Stunden liegt diese bei ca. 38%.

In Abbildung 17 sind die Ergebnisse verschiedener Auswertungen des Markov Modells skizziert. Hier ist erkennbar, dass die Reliability nach 10000 in den ersten Ansätzen deutlich unter 38% liegt. Nach einer testweisen Anpassung der Auswertungslogik für die Reparatur („replace on repair“) konnten der gleiche Wert wie in der RT-CARS Auswertung von 38% erzielt werden.

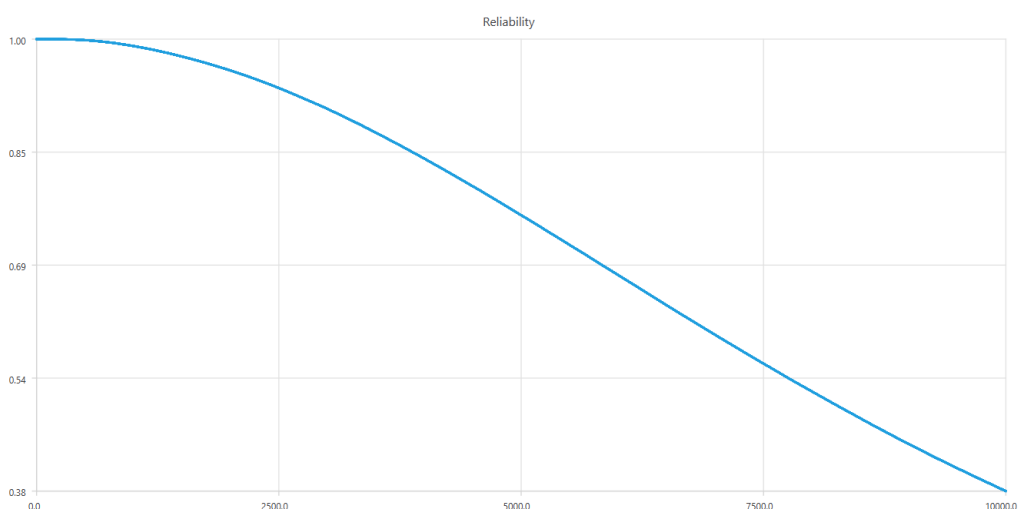


Abbildung 16: RT-CARS Reliability mit Hardware (Sensor) Reparaturen

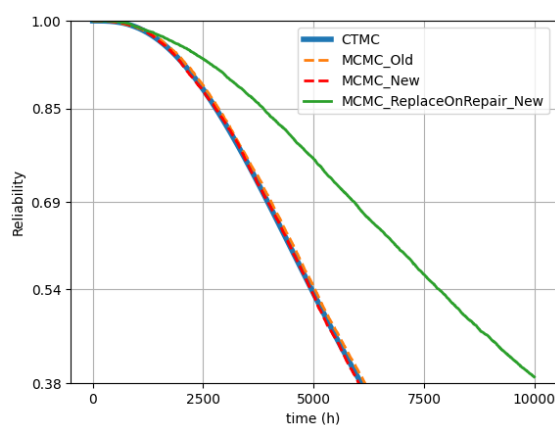


Abbildung 17: Markov Modell Wiederherstellung v.s. Austausch

Damit konnten sowohl Unterschiede der Verfahren deutlich gemacht werden, als auch gezeigt werden, dass bei Angleichung des Reparaturverhalten, beide Verfahren die gleichen Ergebnisse erzeugen. Somit gilt das Verifikationsziel als erreicht.

dSPACE: Weiteren Input in Use Case 2 lieferte dSPACE, in dem die Anwendung von Markov-Modellen zur Bewertung wetterbedingter Auslösebedingungen untersucht wurde. Ziel war es, eine Aussage über unterschiedliche Ausfallraten zu tätigen und damit einen Beitrag zur Erhöhung der Sicherheit autonomer Fahrzeuge unter Berücksichtigung der SOTIF (Safety of the intended Functionality – definiert in ISO 21448) zu leisten.

Nach SOTIF wird ein Risiko (z.B. false-positive Objekterkennung) durch eine Auslösebedingung (z.B. niedriger Sonnenstand) getriggert. Das kann zu einer Gefährdung (fälschlich ausgelöste Notfallbremsung) auf Fahrzeugebene führen. Um das Risiko zu mindern oder zu beheben, kann entweder der Trigger eliminiert werden (z.B. durch eine Einschränkung der ODD) oder das Systemdesign angepasst werden (z.B. Nutzung zusätzlicher Sensorik). Um eine geeignete Maßnahme zur Risikoreduzierung zu wählen, wird die Auftrittswahrscheinlichkeit der Auslösebedingung (Occurance Rating) sowie der Schweregrad auf Fahrzeugebene (Severity Rating) bestimmt.

In dem von dSPACE entworfenen Modell, wurde die Annahme getroffen, dass eine Wetterbedingung eine Auslösebedingung sein kann, die zu einem Risiko führt. Ziel war es, die Auslösebedingungen mittels Markov-Modellen zu modellieren, um deren Auftretenswahrscheinlichkeit zu bestimmen. Dadurch können risikomindernde Maßnahmen in einem frühen Entwicklungsstadium anhand des Occurance Ratings priorisiert werden. Das von dSPACE entworfene Modell umfasste einen iterativen Prozess, der verschiedene Wettersituationen in drei Vorsichtsstufen einteilte: es handelt sich um eine Auslösebedingung, es handelt sich um eine potentielle Auslösebedingung und es handelt sich um keine Auslösebedingung .

Die Ergebnisse der Modellierung zeigten eine gute Leistung und Genauigkeit im Wetterzustandsmodell, während das Übergangsmodell sehr gute Leistungen, jedoch niedrigere Genauigkeiten aufwies. Es wurde festgestellt, dass eine größere Datenmenge benötigt wird, um die Genauigkeit zu verbessern. Zudem hatte die Systematisierung der anfänglichen Wahl erheblichen Einfluss auf die Genauigkeit und Leistung des Modells. Insgesamt konnte gezeigt werden, dass Markov-Prozesse einen relevanten Beitrag zur Erhöhung der Sicherheit autonomer Fahrzeuge unter Berücksichtigung von SOTIF leisten können. Sie ermöglichen eine gezielte Priorisierung von Testszenarien und tragen zur Effizienzsteigerung in der Absicherung automatisierter Fahrfunktionen bei.

EMI: Es wurde eine umfassende Analyse der Ausfallwahrscheinlichkeiten unter verschiedenen Umweltbedingungen durchgeführt und für ein Markov-Modell angepasst. In Zusammenarbeit mit Projektpartnern wurde die Ermittlung von Ausfallraten anhand vorhandener Datenbanken erörtert. Ein konkretes Beispiel ist die Ausfallrate der Radarsensorik, die auf den HU-Daten der DEKRA basiert. Hierbei wurden alle LKW mit Erstzulassung ab 2018 betrachtet, da diese zwingend mit Radarsensorik ausgestattet sind. Die Daten enthielten auch die Laufleistung der LKWs, was die Erstellung einer zeitabhängigen Ausfallrate in Abhängigkeit vom Laufleistung bzw. Alter der Sensorik ermöglichte. Die Messdaten wurden durch eine Weibullkurve approximiert, siehe Abbildung 18. Das Beispiel zeigt, dass Ausfallraten für die Sensorik erstellt werden können, sofern die entsprechenden Daten zur Verfügung stehen.

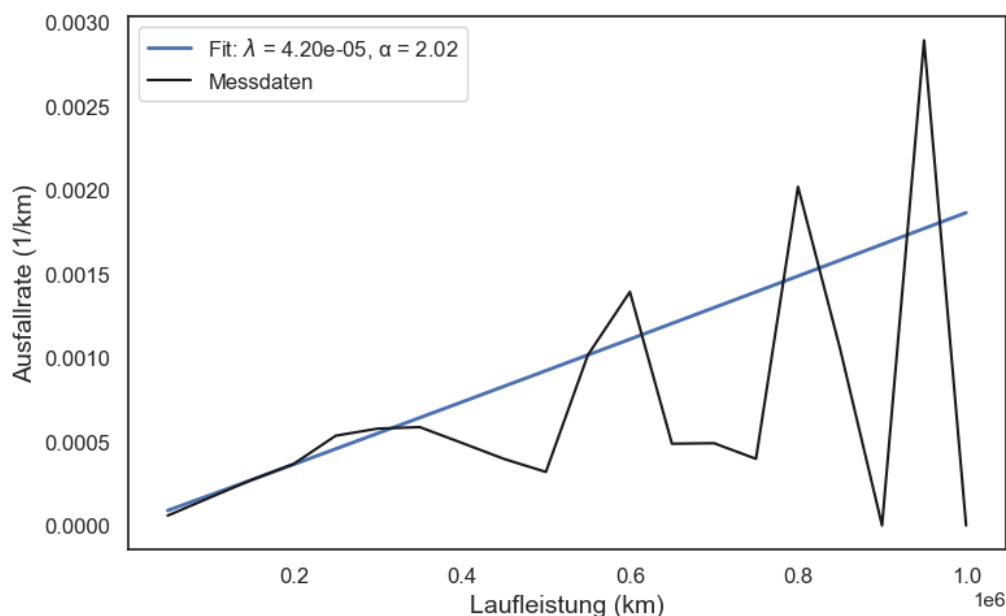


Abbildung 18: Ausfallrate für die Radarsensorik von LKW basierend auf HU-Daten.

Um dem Ziel die Zustandsraumexplosion in den Griff zu bekommen näherzukommen wurden verschiedene Ansätze getestet. Die Berechnungszeit wurde durch Verfahren auf dem Stand der Technik in einem Python-Framework implementiert und optimiert. Weiterhin wurde ein Ansatz zur Modularisierung für einzelne Teile des Fahrzeugs durchgeführt und so das Gesamtmodell auf mehrere kleiner Markov-Modelle verteilt. Ein Anwendungsbeispiel war ein System mit 4374 Zuständen welches in ein Modul mit 189 Zuständen und ein modularisiertes Modell mit 48 Zuständen vereinfacht werden konnte, siehe Abbildung 19. Mit dem modularisierten Ansatz wurde eine 100-fache Beschleunigung der Simulationszeit erreicht, während die Genauigkeit der Gesamtsystemzuverlässigkeit innerhalb von 1,5 % blieb. Diese Methode öffnet die Tür zur Simulation komplexer Systeme, die von Komponentenmodellen bis hin zu einem ganzen Fahrzeug reichen und externe Faktoren einschließen.

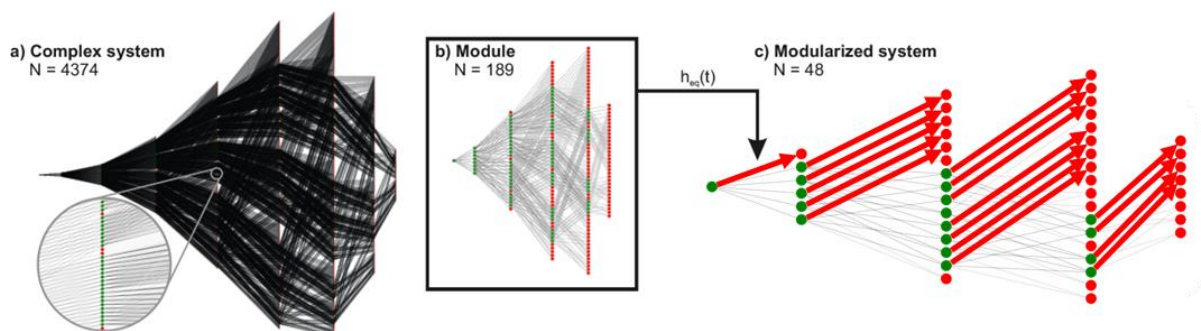


Abbildung 19: Modularisierung eines Systems

Die Einbindung von Machine Learning (ML) und Künstlicher Intelligenz (KI) war ein Versuch zur Effizienzsteigerung der Solver und Algorithmen. Ein einfaches neuronales Netz wurde entwickelt und trainiert, um die Simulationsergebnisse zu unterstützen, und es wurden Daten für hochdimensionale Modelle generiert, um Benchmarks für die Leistungsverbesserung zu erstellen. Es wurden zwei Ansätze untersucht, um das Markov-Modell zu ersetzen - eine Multilayer Perceptrons (MLP) sowie eines Convolutional Neural Network (CNN). Die Benchmarks dazu zeigen, dass im betrachteten Ausschnitt die direkte Markov-Modellierung schneller war, siehe Abbildung 20. Eine Extrapolation lässt jedoch erahnen,

dass sich dies bei sehr vielen States umkehren wird. Sowohl das MLP-Modell als auch das CNN-Modell weisen einen geringen Testverlust und eine hohe Kosinusähnlichkeit auf.




Abbildung 20: Benchmark für Markov, MLP und CNN-Modell

Die Markov Modellierung wurde im Rahmen des Use Case auf die Sensorik des INYO-Testfahrzeugs der THA und somit auf ein reales Fahrzeug angewandt. Das Ergebnis des Wettereinflusses dazu ist in Abbildung 21 zu sehen. Letztendlich wurden die Ergebnisse mit RT-Cars abgeglichen und ergaben eine Übereinstimmung.




Abbildung 21: Demonstrative Anwendung des Modells und der Einfluss von Wetter auf die Gesamtzuverlässigkeit

Use Case 3: Vehicle Dynamics Modell Validierung & Absicherungs Blueprint

Use Case 3 soll ein Vehicle Dynamics Modell und ein Absicherungs-Blueprint liefern. Hierzu wurde der zentrale Baustein der Erhöhung der Fahrzeugsicherheit als Ausgang für einzelne zuarbeitenden Partner in den jeweiligen Projektteilbereichen gewählt (Abbildung 22).

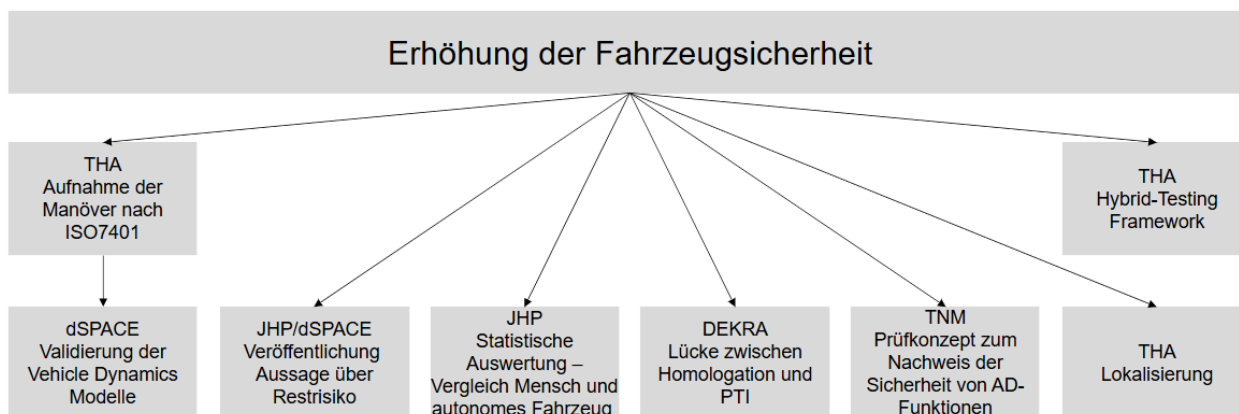


Abbildung 22: Überblick zu Use Case 3

Die Erhöhung der Fahrzeugsicherheit kann über den gesamten Lebenszyklus hinweg geschehen. Der gesamte Lebenszyklus eines Fahrzeugs im Hinblick auf die Einhaltung gesetzlicher Vorgaben in der Europäischen Union ist komplex. Dieser Prozess beginnt in der Phase der Entwicklung und Produktion, in der das Gesamtfahrzeug nach den Anforderungen der (aktuellen) Rahmenverordnung (EU) 2018/858 [3] sowie deren Durchführungsverordnungen und relevanten UN-ECE-Regelungen für Einzelsysteme entwickelt und konstruiert wird. Weiterhin sind Normen (ISO/SAE) welche in den vorgenannten Regulierungen genannt sind relevant. Diese Verordnungen und Normen stellen die „Bauvorschriften“ für Straßenfahrzeuge innerhalb der EU dar. Anschließend erfolgt die Typp Genehmigung bei der die Einhaltung der vorgenannten Vorschriften überprüft oder in manchen Fällen vom Hersteller bestätigt werden. Hierbei wird der „Typ“ oder das „Model“ des Fahrzeugs genereller Art überprüft. Die Überprüfung erfolgt durch akkreditierte „Technische Dienste“. Die Zulassung des „Models“ durch die jeweilige nationale Zulassungsbehörde (in D: KBA) für die gesamte EU. Innerhalb dieser Typprüfung gibt es weitere Maßnahmen wie die sogenannte CoP-Prüfung (Conformity of Production) bei der der Hersteller sicherstellen muss, dass jedes individuelle Fahrzeug so spezifiziert, produziert und hergestellt wird wie das exemplarische typgeprüfte Model. Nach der erstmaligen Erstzulassung dieses individuellen Fahrzeugs beginnt die Nutzungsphase. In dieser Phase wird die gesetzliche Konformität durch verschiedene Maßnahmen überwacht: Die In-Service Conformity (ISC) überprüft stichprobenartig, ob Fahrzeuge im realen Betrieb weiterhin die Vorgaben erfüllen. Die Periodical Technical Inspection (PTI) – also die regelmäßige Hauptuntersuchung gemäß EU Richtlinie 2014/45/EU [9] – stellt sicher, dass sicherheits- und umweltrelevante Funktionen in regelmäßigen Abständen kontrolliert werden. Diese EU-Richtlinie wird in Deutschland durch den §29 StVZO umgesetzt/erfüllt [1]. Ergänzt wird dies für Nutzfahrzeuge durch zufällige Straßenkontrollen (Road Side Inspection, RSI) sowie durch eine kontinuierliche sog. Marktüberwachung, bei der Behörden im Verkehr befindliche Fahrzeuge systematisch prüfen. Der Lebenszyklus endet schließlich mit der „endgültigen Außerbetriebsetzung“ des Fahrzeugs. Insgesamt zeigt vorgehende Erläuterung, wie über den gesamten Lebensweg eines Fahrzeugs hinweg verschiedene Mechanismen ineinandergreifen, um eine lebenslange Konformität sicherzustellen.

DEKRA: In Use Case 3 hat DEKRA die Lücke zwischen der HU und der Homologation analysiert, um aufzuzeigen wo Herausforderungen bei der Prüfung von Hochautomatisierten Fahrfunktionen im Rahmen der PTI liegen. Nimmt man die zentralen Trends in der Fahrzeugentwicklung und die zunehmende Automatisierung der Fahrfunktionen, ergeben sich mehrere Handlungsfelder für die

HU/PTI. Um die beschriebenen Aufgaben und Ziele des Staates bzw. der EU sicherzustellen, muss die Sicherheit über den gesamten Lebenszyklus eines Fahrzeugs gewährleistet sein. Die HU/PTI kann im Rahmen ihrer Möglichkeiten nur effektiv sein, wenn eine enge Verknüpfung der Vorgaben von Typprüfung, regelmäßiger HU/PTI und Marktüberwachung gegeben ist. Ein weiteres zentrales Thema ist der Zugang zu Fahrzeugdaten, sei es über physische Diagnoseschnittstellen oder online über herstellereigene Server im Falle von OTA-Übertragungen – oft verbunden mit Zugangsrestriktionen wie Zertifikaten. Ebenso wichtig ist die Standardisierung der Diagnosedaten, etwa im Rahmen von ISO 20730 für „ePTI“ [6] [7]. Neue Prüf- und Fahrzeugtechnologien, beispielsweise im Bereich automatisierter Fahrfunktionen, softwareintegrierter Systeme oder Cybersecurity, erfordern angepasste Prüfverfahren. Insgesamt muss sich die Prüfstelle der Zukunft mit neuen Prüfmitteln, Geräten und Anforderungen weiterentwickeln, sowie natürlich die Prüfer/Durchführenden entsprechend schulen und befähigen um den technischen Wandel der Fahrzeugwelt adäquat abzubilden.

Die grundlegenden Anforderungen an die Periodische Technische Inspektion (PTI) bildet insbesondere die Rahmenbedingungen der EU-Richtlinie 2014/45/EU. Diese fordert, dass technische Überprüfungen von Fahrzeugen im Verkehr einfach, schnell und kostengünstig sein sollen, gleichzeitig, aber effektiv zur Erreichung der Sicherheits- und Umweltziele beitragen müssen. Daraus ergeben sich mehrere praktische Leitlinien für die Gestaltung der PTI: Die Prüfungen sind zeitlich begrenzt und müssen daher möglichst effizient gestaltet werden; Investitionen in neue Prüfmittel und -prozesse bleiben ebenfalls begrenzt da sich diese auf die Kosten der Untersuchung auswirken. Neue Methoden sollten immer in bestehende Abläufe integriert werden, ohne diese unnötig zu verkomplizieren. Besonders wichtig ist das frühzeitige Erkennen schwerer Fehler oder sicherheitsrelevanter Defekte, wobei der Prüfumfang (Scope) klar definiert sein muss. Insgesamt muss ein bestmögliches Verhältnis zwischen Aussagekraft der Prüfung und dem dafür benötigten Aufwand erreicht werden, um einen hohen Wirkungsgrad sicherzustellen.

Verknüpft man das damit, dass EU-Vorschriften zur Typgenehmigung und Homologation zugleich als technische Design- und Bauvorschriften für Fahrzeuge gelten, damit die Anforderungen der PTI später erfüllt werden können, müssten die relevanten Aspekte bereits in diesen frühen Vorschriften berücksichtigt werden. Dadurch würde ein durchgängiger Zusammenhang zwischen Fahrzeugentwicklung, Typprüfung und späterer regelmäßiger technischer Überwachung entstehen.

Die PTI ist aktuell zwar als Maßnahme innerhalb der vorgenannten Anforderungen an den Bau der Fahrzeuge (Typprüfung) genannt, jedoch sind die konkreten Umsetzungen und tatsächlichen Berücksichtigungen noch sehr klein. Insbesondere für neue und zukünftige Fahrzeuge ist eine enge „Verlinkung“ für eine effiziente Umsetzung der HU/PTI in der EU unbedingt erforderlich.

dSPACE: In Use Case 3 war ein zentraler Bestandteil die Validierung eines Vehicle Dynamics Fahrzeugmodells. Validierte Modelle bilden die Voraussetzung, um für virtuelle, homologationsrelevante Tests genutzt zu werden. Durch die Verlagerung der Tests in die virtuelle Umgebung ergeben sich erhebliche Vorteile wie die Abbildung von Szenarien mit hoher Komplexität und Wiederholbarkeit, die im realen Testbetrieb nur eingeschränkt oder gar nicht umsetzbar wären. In der ISO 22140 wird eine Methodik zum Vergleich von Simulationsergebnisse mit gemessenen Testdaten nach ISO 7401 spezifiziert. Befindet sich das Fahrzeugverhalten innerhalb eines in der ISO 22140 bestimmten Toleranzbereiches, gilt das Modell als vertrauenswürdig und validiert

Dazu wurden durch die TH Augsburg Manöver nach ISO 7401 mit dem INYO-Fahrzeug auf dem Testgelände in Penzing durchgeführt und Geschwindigkeiten und Lenkwinkel geloggt. Anschließend wurde durch dSPACE das Einschwingverhalten des realen Fahrzeugs mit dem Einschwingverhalten des simulierten Modells nach ISO 22140 verglichen, indem Werte und Funktionen im Zeitbereich betrachtet

wurden. Im ersten Schritt wurde das Fahrzeugmodell auf Basis realer Parameter erstellt und die Testszenarien nach ISO 22140 simulativ durchgeführt. Bevor die gemessenen Signale ausgewertet werden konnten, war eine Signalverarbeitung erforderlich.

Im Rahmen der Validierung wurden die gemessenen Testdaten mit den Simulationsergebnissen verglichen. Im Zeitbereich wurden Step-Input und Sinusoidal-Input (eine Periode) analysiert. Dazu wurden Vergleichsdiagramme der Eingangssignale (Fahrzeuggeschwindigkeit und Lenkwinkel) sowie der Ausgangssignale (Giergeschwindigkeit und Querbearschleunigung) erstellt. Die Berechnung der Key Performance Indikatoren (KPI) erfolgte auf der Basis von prozentualen Fehlern. Der Vergleich der Eingangsgrößen zeigte, dass die Simulation die reale Messfahrt exakt nachbilden konnte. Hierdurch ergab sich die Grundannahme, dass auch die Ausgangsgrößen zwischen Modell und Messung vergleichbar werden.

Die Ergebnisse zeigten deutliche Abweichungen der Gierrate und Querbearschleunigung mit initialen Parametern. Nach erfolgter Optimierung zeigten Messung und Simulation eine deutlich verbesserte Übereinstimmung. Anhand von KPIs lies sich erkennen, dass das Simulationsmodell die geforderten Toleranzbereiche einhielt. Die Ergebnisse waren ein integraler Bestandteil der übergreifenden Sicherheitsmodellierung und Systemintegration.

JHP: In Use Case 3 stand das Thema der Absicherung im Fokus der Arbeiten von JHP. Basierend auf einem kontrollierten Großversuchsprojekt des Department of Motor Vehicles (DMV) in den USA entstand ein großer Datensatz bzgl. des Unfallgeschehens von autonomen Fahrzeugen im Stadtbetrieb in San Francisco. Die zur Verfügung stehenden Daten wurden von uns analysiert, bereinigt und ausgewertet. Günstigerweise existiert für den gleichen Zeitraum auch ein Datensatz für menschliche Fahrer resultierend aus einer anderen Forschungsaktivität in den USA ebenfalls für den Stadtbereich San Francisco. Basierend auf den gesamten Daten entstand eine statistische Studie zum Vergleich der Unfallintensität autonomer Fahrzeuge vs. menschlicher Fahrer. Es wurde das statistische Vorgehen gezeigt, welches notwendig ist, um Qualifikationsgrenzen für autonome Fahrzeuge zu bestimmen, wenn die Forderung besteht, dass ein autonomes Fahrzeug bzgl. der Unfallintensität nicht schlechter oder sogar besser sein muss als menschliche Fahrer. Es konnte gezeigt werden, dass der Nachweis dieser Forderungen am Beispiel San Francisco praktisch möglich wäre. Der Hauptgrund dafür ist, dass die menschliche Unfallintensität vergleichsweise hoch ist. Die Ergebnisse der Arbeit wurden veröffentlicht.

Ein weiterer Aspekt der Absicherung liegt auf dem Nachweis der ausreichenden Abdeckung von Verkehrsszenarien innerhalb der ODD, die im Rahmen einer Veröffentlichung zwischen JHP und dSPACE behandelt wurde. Dabei gilt: Je seltener bislang nicht beschriebene (unbekannte) Szenarien auftreten, desto höher ist die Wahrscheinlichkeit, dass der Szenarioraum innerhalb der ODD größtmöglich abgedeckt ist. Zusammen mit dem Projektpartner dSPACE konnte JHP hier eine statistische Lösung für diesen Nachweis erarbeiten. Basierend auf einem nicht-homogenen Poisson-Prozess wurde der real existierende Ablauf der Identifikation von bisher unbekanntem Szenarien statistisch modelliert. Es entsteht ein allgemeines Modellgerüst, welches an die spezifische bisherige Identifikationshistorie angepasst werden kann. Aus den resultierenden Modellparametern lässt sich bestimmen, wie hoch das Risiko für noch nicht identifizierte Fahrscenarien ist. Hierzu wird eine sog. Auftretensrate bisher unbekannter Szenarien definiert. Mit dieser Vorgehensweise konnte ein wichtiger Beitrag geleistet werden, um den Anforderungen an der Validierung und Absicherung von Fahrerassistenzsystemen (ADAS) und automatisierten autonomen Fahrfunktionen (AD) in modernen Fahrzeugen gerecht zu werden. Die entwickelte Vorgehensweise wurde veröffentlicht.

TNM: Grundlage der Arbeiten von TÜV NORD Mobilität im Use Case 3 war die Untersuchung von Anforderungen, konzeptionellen Methoden und die Ableitung von Prüfanforderungen zur Entwicklung von Prüfverfahren für das hoch- und vollautomatisiertem Fahren.

Zur Spezifikation von Anforderungen für den Einsatz von Funktionen für das hoch- und vollautomatisierte Fahren wird aktuell eine Normungsroadmap entwickelt, welche unter anderem allgemeine Anforderungen an die Nachweispflicht berücksichtigen soll und deren Inhalte in die Arbeiten eingeflossen sind.

Zusätzlich zu den Normen sind auch verschiedene Regelungen (z.B. R157, R171) und Verordnungen (AFGBV, 2022/1426) erschienen, die sich mit Anforderungen an die Sicherheit von hoch- und vollautomatisierten Fahrzeugen richten.

Aus den erschienenen Normen, Regelungen und Verordnungen wurde begonnen einen Prüfplan zu entwickeln, mit dem eine Typprüfung von autonomen Fahrzeugen erfolgen soll. Dazu zählen nicht nur die rein technischen Aspekte an automatisierte Fahrfunktionen, sondern auch prozessionelle, die bei der Entwicklung und Prüfung von automatisierten Fahrfunktionen zu berücksichtigen sind.

Use Case 4: Datentransfer für Teleoperation:

Im Rahmen des Use Case 4 war geplant exemplarisch Validierungen im Feld über geeignete Kommunikationsstrukturen in Kombination mit dem in AP 6 konzipierten TelTaKo-S zu realisieren. Nachdem für eine Kooperation mit dem Testfeld Karlsruhe im Rahmen von RDV keine Mittel bewilligt wurden, konnten die wesentlichen Ziele mit eigenen Mitteln, wie z.B. vorhandenen Fahrzeugen, realisiert werden.

RA Consulting GmbH: RAC hat im Use Case 4 sowohl das Konzept des TelTaKo-S in Form einer exemplarischen Implementierung aus AP 6 validiert, und dazu auch reale Fahrzeuge mit entsprechenden Sensoren und Zusatzsystemen ausgestattet, um geeignete Validierungsszenarien abbilden zu können. Die Validierungen selbst konnten dann weitestgehend, wie in AP 9.1 vorgesehen, in reduzierter Form mit den eigenen Fahrzeugen durchgeführt werden.

Hintergrund für die Validierungen im Feld waren unterschiedliche Anforderungen, die sich zum einen aus dem Aufbau des Gesamtsystems, aber auch aus den Anforderungen des jeweiligen Anwendungsszenario ergeben. Die folgenden Abbildungen zeigen sowohl die Kommunikations-Umgebung des Zielfahrzeugs (SUT), als auch die Klassifizierung der möglichen Einsatzszenarien.

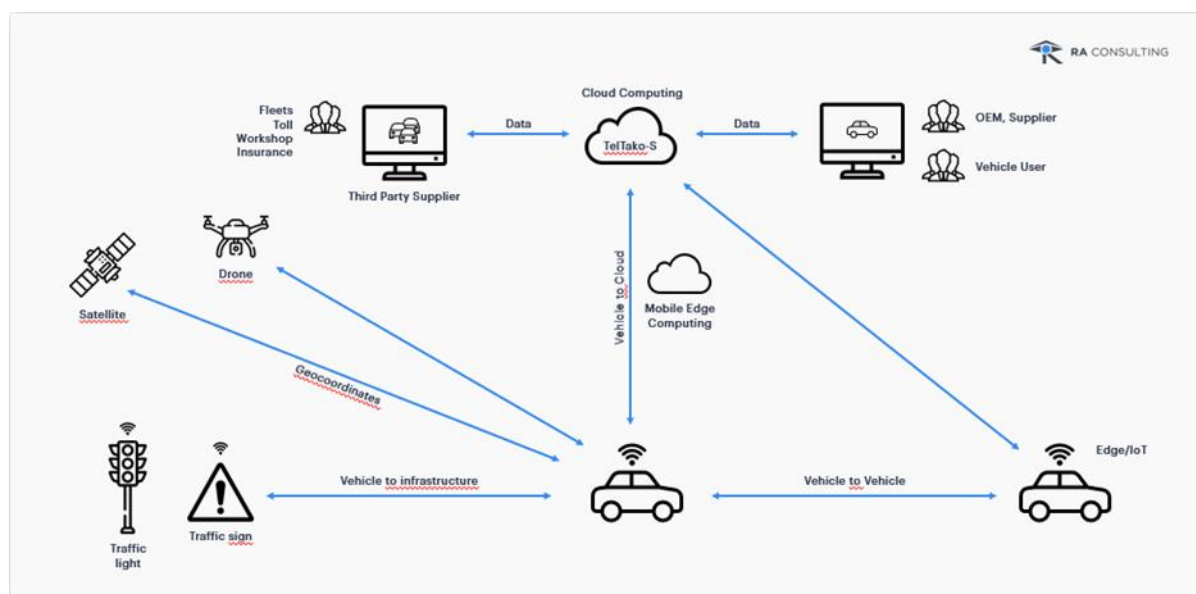


Abbildung 23: Überblick über die externen Kommunikationsschnittstellen eines Fahrzeugs

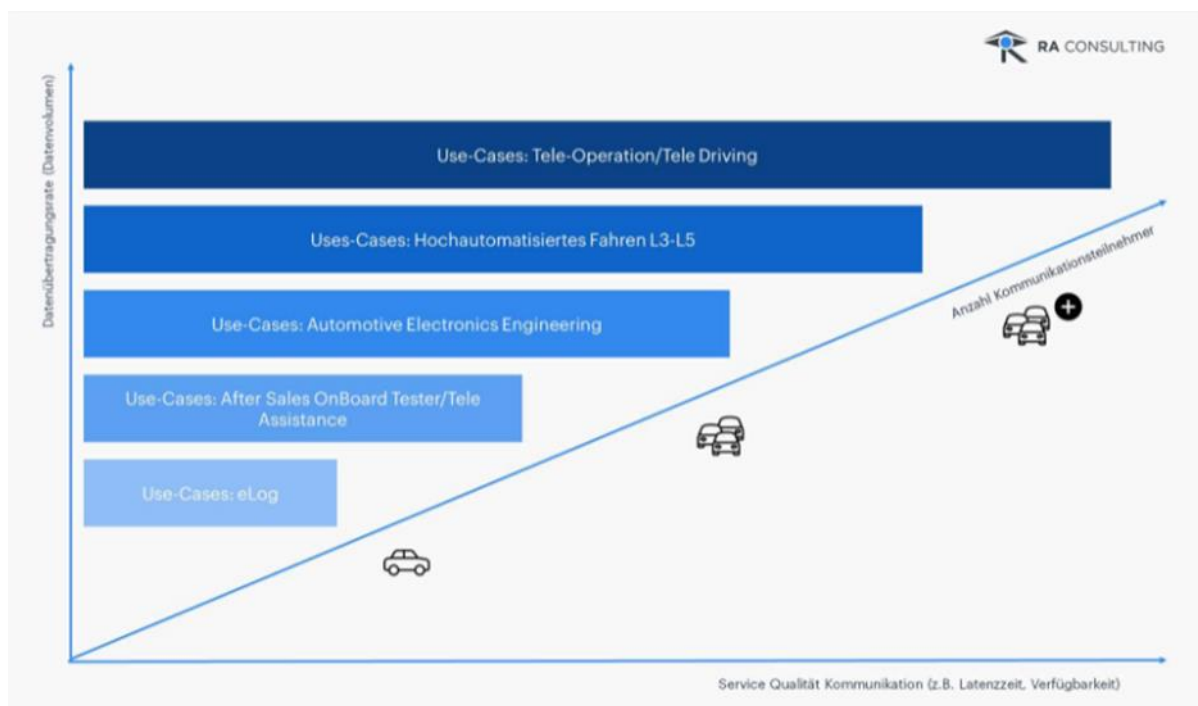


Abbildung 24: Unterschiedliche Einsatzszenarien als Validierungs-Use-Cases

Die arbeiten in Use Case 4 fokussierte sich daher auf die folgenden Ziele:

- Entwicklung standardisierter Szenariobeschreibungen und Methoden zur Datenaufbereitung,
- Analyse der Kommunikationsanforderungen für Validierungen unter realen Einsatzbedingungen,
- Entwurf einer modularen Systemarchitektur für die Middleware,
- prototypische Implementierung der Kernkomponenten,
- Evaluation der Prototypen unter realistischen Testbedingungen.

Diese Ziele wurden im Wesentlichen erreicht. Sowohl Szenarienbeschreibungen als auch Datenaufbereitungs Pipelines wurden definiert. Kommunikationsanforderungen wurden systematisch analysiert, wobei unterschiedliche Anwendungsfälle wie Telemetrie, Tele-Assistenz, Tele-Visualisierung, Tele-Steuerung und Tele-Operation klar unterschieden wurden. Eine modulare Systemarchitektur wurde entworfen, mit Komponenten für Authentifizierung, Monitoring, Alarmierung, Aufgabenplanung, Provisionierung und Kommunikation.

Auf Basis der konzipierten Architektur aus AP 6 wurden für die unterschiedlichen Validierungs-Use-Cases entsprechende Prototypen implementiert und im realen Umfeld getestet. Darunter die Echtzeit-übertragung von OBD-II und GPS-Daten, die Übermittlung von Objektlisten sowie Videostreaming über WebSocket. Die Evaluation erfolgte auf einem Testfeld und bestätigte sowohl die Machbarkeit als auch die Leistungsfähigkeit des Systems.

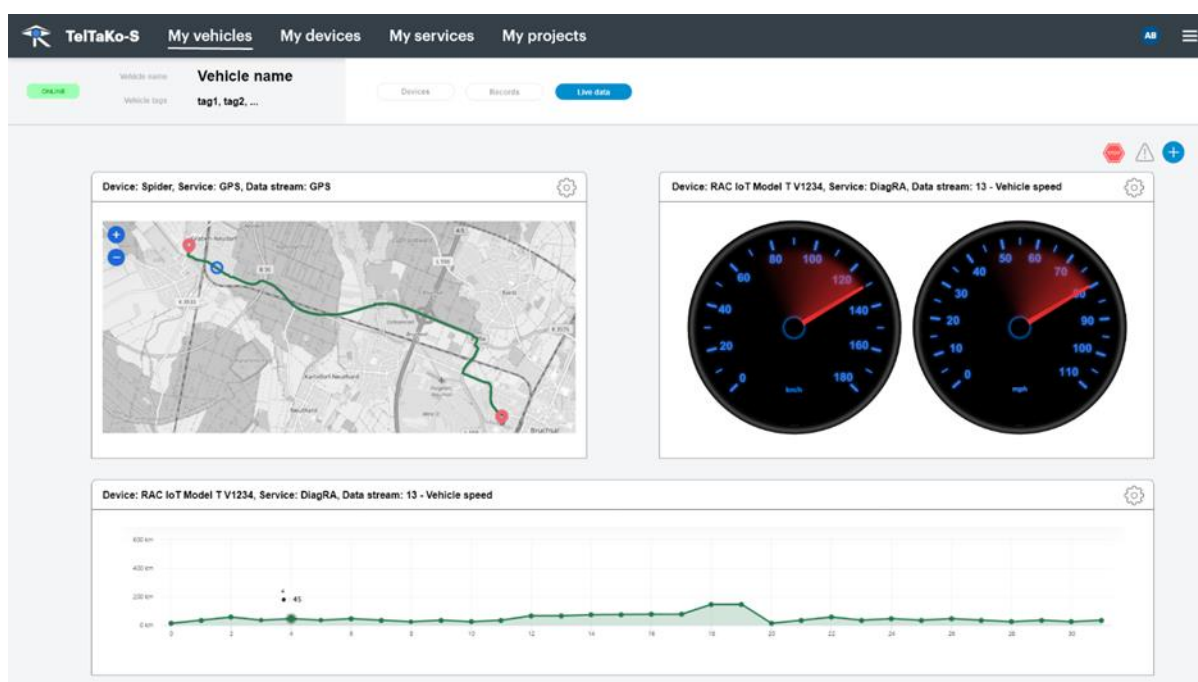


Abbildung 25: Exemplarisches Dashboard zur selektiven Visualisierung von Fahrzeugdaten

So war es möglich zu einzelnen Validierungsaufgaben entsprechende Remote-Visualisierungen zu erstellen, die dann die skalierbare Übertragung von Messwerten erlaubt. Dabei wurden die zu übertragenden Daten hinsichtlich der verfügbaren Bandbreite priorisiert und geeignet übertragen. Bei Video-Daten konnte z.B. die Skalierung, sowie die Frame-Rate der Videodaten angepasst werden, um auch eine schmalbandige Übertragung zu realisieren, wenn für den Anwendungsfall erforderlich.

Neben der Web-basierten Dashboard-Darstellungen, wurden auch Untersuchungen und Konzepte, u.a. in Form von Mockups, zu entsprechenden Erweiterungen der bei RA bereits vorhandenen Werkzeuge aus dem Bereich Messen und Kalibrieren erstellt. Soweit möglich wurden bereits vorhandene Visualisierungen verwendet. Diese Erweiterungen umfassen dabei

- Erweiterung der Darstellung um eine Video-Funktion
- Ergänzung um eine Streaming-API, um Messdaten auch über Remote-kanäle bereitstellen zu können
- Aufzeichnung aller Daten in eine geeignete Messdatei
- Adaptionen zur Aufzeichnung der neuen Datentypen im neuen ASAM MDF Format 4.3

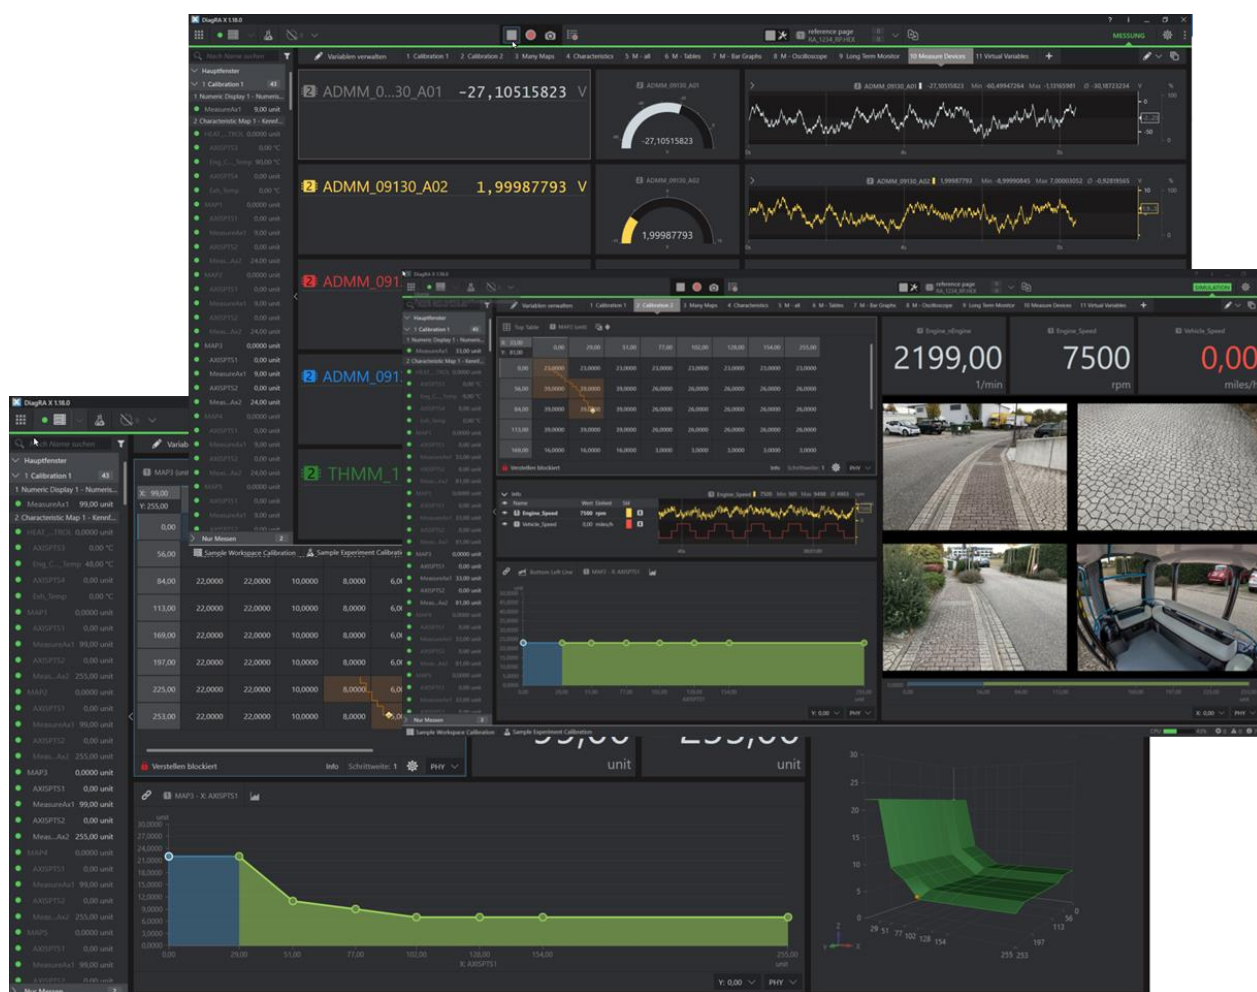


Abbildung 26: Anpassungen und Erweiterungen (Mockup) in DiagRA-X

Kommunikation

Für die Untersuchungen zum Datenaustausch wurde unter Zuziehung eines qualifizierten, externen Projektpartners, dessen Arbeitsanteile nicht öffentlich gefördert wurden und durch die RA Consulting GmbH finanziert wurde, eine ergänzende und umfassende Studie erstellt. Die dort ermittelten Anforderungen wurden dann sowohl im Rahmen des AP 6 bei der Server-Konzeptionierung als auch bei der Selektion der Kommunikationskanäle berücksichtigt. Insbesondere war es erforderlich, Verbindungen mit niedrigen Latenzzeiten zu nutzen.

In einer Kooperation mit der Telekom wurden zunächst Untersuchungen mit einer experimentellen API zur Quality of Service (QoS)-Steuerung vorgenommen. Dabei konnte ermittelt werden, wie QoS-Anforderungen aus den Anwendungsszenarien abgeleitet werden können. Eine Umsetzung über die API reichte jedoch nicht aus, da diese zum einen bei der Inanspruchnahme über die API verbesserter Kommunikation-Service-Qualitäten eng zeitlich begrenzt war, und zum zweiten auch die Varianz der Stellgrößen den Anforderungen nicht gerecht wurde.

In einer weiteren Evaluierung wurden dann Satelliten-Kommunikation näher untersucht. Insbesondere das Starlink-System bietet hinsichtlich Kommunikations-Latenzen zu den bislang nutzbaren geostationären Systemen deutliche Vorteile. So wurden zunächst Untersuchungen auf Basis der stationären Variante durchgeführt, um grundsätzliche Informationen zu Durchsatz und Latenz, wie im Folgenden dargestellt, zu bekommen.




Abbildung 27: Messungen zu Latenz und Datendurchsatz im Starlink-System

Die dabei ermittelten Werte von durchschnittlichen 20MB/s im Download und 6MB/s im Upload, bei einer durchschnittlichen Latenz von 20ms, erfüllen zwar nicht alle Anforderungen der Studie, decken aber einen deutlich breiteren Bereich ab als die im Mobilfunknetz gemessenen Werte. Insbesondere, wenn es sich um eher ländliche Gebiete handelt.

Für die Fahrzeugausrüstung und die durchgeführten Validierungen wurde dann schließlich auf das mobile System (Mobile/Mobility) von Starlink zurückgegriffen, bei dem die Antenne auch an beweglichen Objekten befestigt werden kann, wie in der folgenden Abbildung dargestellt, und auch weiter unten am Beispiel des VW-Bus ersichtlich ist.



Features	Mobile/Mobility	Roam
Download Speed	40 Mbps – 220 Mbps	5 Mbps – 50 Mbps
Upload Speed	2 Mbps – 10 Mbps	8 Mbps – 25 Mbps
Latency	<99 ms	<99 ms
Pricing Subscription (US)	50 GB: \$250 1 TB: \$1,000 5 TB: \$5,000	Regional: \$150 Global: \$200
Recommended Hardware	Flat High Performance Dishy	Standard Dishy
Pricing Hardware	\$2,500	\$599
Prioritization	Priority Access Data	Basic Access Data
Availability	Worldwide	Regional: in registered country Global: Worldwide
In-Motion Usage	Allowed	Not Allowed (if using Standard dishy)

Quelle: starlink.com

Abbildung 28: Aufbau und Eigenschaften des Mobilten Starlink-Systems

Sensor- und Fahrzeugdaten

Um realitätsnahe Kommunikationsszenarien zu haben, wurden entsprechende Sensoren, wie z.B. LIDAR eingesetzt, die ein entsprechendes Datenaufkommen realisieren konnten. Auch wurden unterschiedliche Fahrzeuge für die Validierungstests genutzt; diese und auch die mit diesen Fahrzeugen durchgeführten Validierungen sind bei den Demonstratoren als Messfahrzeuge RAC-1 bis RAC-3 detailliert beschrieben.

Im Ergebnis aller durchgeführten Tests konnte bestätigt werden, dass die zugrunde liegenden Validierungsszenarien jeweils erfolgreich abgebildet werden konnten.

Use Case 5: AD Reference-System & AD MW & Computing Test System

TTTech: Im Use Case 5 und als Verifikation des AP 11 wurde mit einem Blick auf zukünftige SAE Level 4&5 Anwendungen ein Referenz-System für hoch-automatisiertes/autonomes Fahren entwickelt und als Use Case Demonstrator aufgebaut, das die zu erwartenden extrem hohen Computerleistungen in einem zentralen Rechneransatz erbringen kann. Weiters wurde mit dem zweiten Teil ein automatisiertes Test-System hinzugefügt, das die Funktionalität entsprechend den Anforderungen automatisiert erfüllen kann. Dabei wurden neben Service oriented Architecture Grundlagen, die für Software defined Vehicle Anwendungen benötigt wird, auch eine Funktionalität im Referenz System eingebaut, die als „Organic Computing“ bezeichnet wird. Diese Funktion ist in der Lage einen „Health State“ des Systems mit den Steuerdaten an den zentralen Rechner mit zu übertragen, und ggf. auch korrektive, „selbstheilende“ Strategien und Technologien anzuwenden, um die Verfügbarkeit des Steuersystems zu erhöhen. Dabei wurden im Speziellen auch die zeit-kritischen Parameter im System entsprechend berücksichtigt, um die sicherheits-kritischen Funktionen nicht zu beeinträchtigen.

Eine weitere Komponente, die sowohl im Referenz System als auch im Test-System seinen Niederschlag gefunden hat, ist die Anforderung, trotz stets steigender Notwendigkeit für höhere Rechenleistungen auch mit „schwächeren“ Systemen auch für hohe Automatisierung und ggf. autonome Steuerung das Auslangen zu finden. Für diese komplexe Aufgabe wurde ein Software Modul-Paket entwickelt, das aus TTT-Executor und TTT-Orchestrator besteht. Es ist in der Lage, die Steuerfunktion derart zu optimieren, dass das System auch mit schwächerer Computerleistung das Auslangen finden kann. Dies wurde in dem System aus Referenz-System und Test-System eindrucksvoll bewiesen, indem ein Fahrzeug im Modell einmal mit und einmal ohne dieses SW Modul Paket betrieben wurde. Dabei waren die „physischen Steuerrechner“ quasi „in the loop“ eingebaut und die Steuerfunktion wurde lediglich modelliert. Dieser Aufbauteil bewerkstelligt in erster Linie die Erstellung der Umfeldwahrnehmung und daraus abgeleiteter Lenk-, Brems- oder Beschleunigungs- Befehle. Das Fahrzeug konnte eine hindernisbehaftete Strecke fehlerfrei durchfahren, wenn das Modul eingeschaltet war und hat ohne das Paket die Aufgabe nicht bewältigen können.

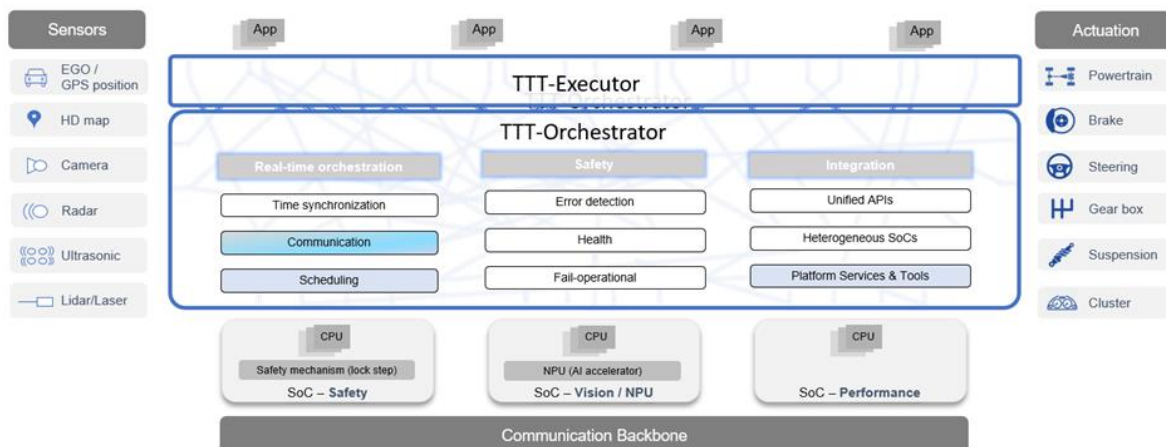


Abbildung 29: Architektur Bild des Aufbaus

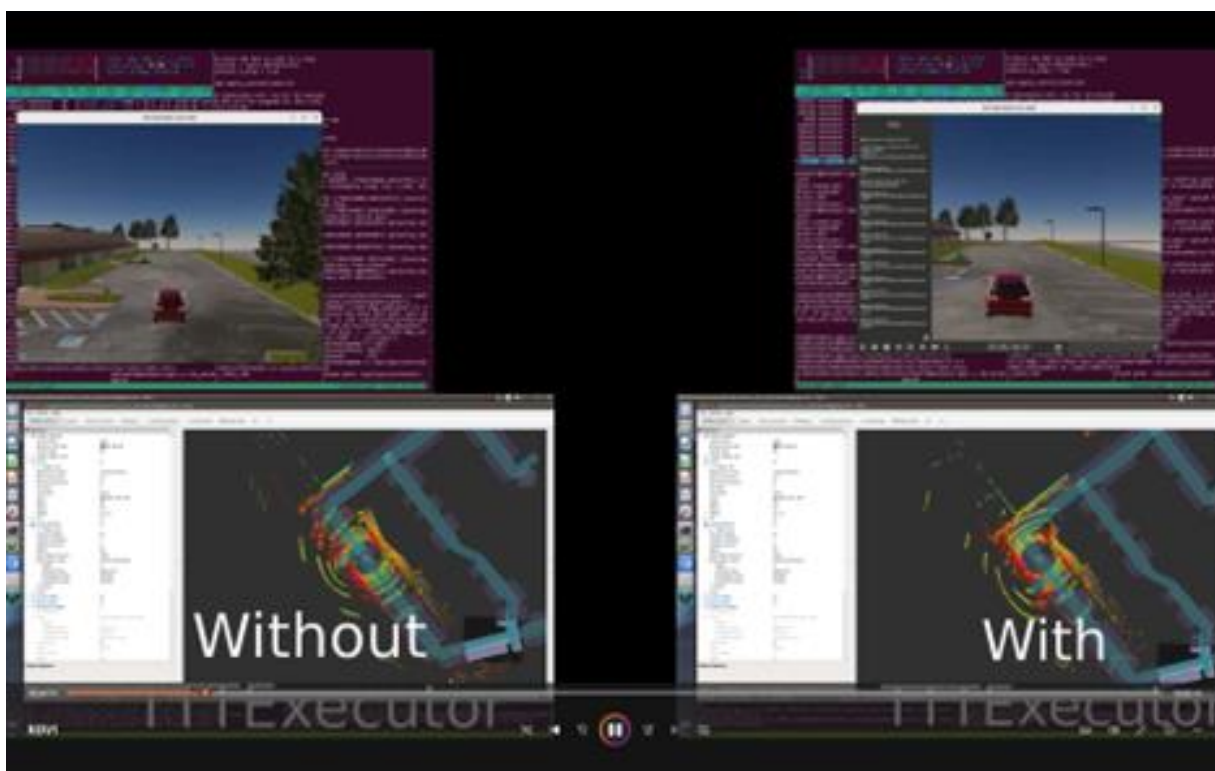


Abbildung 30: Ausschnitt aus Präsentationsvideo des TTT-Executor/ TTT-Orchestrator Aufbaus im AD Referenzsystem.

Abbildung 30 stellt die Performance mit und ohne der beiden SW Komponenten im Vergleich dar. Ohne TTT-Executor / TTT-Orchestrator ist die weniger leistungsfähige HW nicht in der Lage das Fahrzeug zufriedenstellend zu steuern und verlässt immer wieder die Fahrbahn bzw. verursacht Kollisionen, mit den beiden Komponenten funktioniert die Steuerung trotz Verwendung einer weniger leistungsfähigen HW und derselben Application SW.

2.1.15 DEMONSTRATOREN

Im Rahmen von Real Driving Validation gab es verschiedene Demonstratoren, die im folgenden beschrieben sind.

- 1) Sensormessfahrzeug (dSPACE)

- 2) Inyo Leichtbau Shuttle (TH Augsburg)
- 3) Sensormessfahrzeug RAC-1 (RAC)
- 4) Sensormessfahrzeug RAC-2 (RAC)
- 5) AD Referenzsystem und automatisches AD MW & Computing Test System (TTTech)

Tabelle 4: Demonstrator Sensormessfahrzeug


Name des Demonstrators	Sensormessfahrzeug
Verantwortlicher Partner	dSPACE GmbH
Typ des Demonstrators	Reales Fahrzeug auf Basis eines BMW 3er
Einsatzort des Demonstrators	Reales Testfeld, öffentlich: allgemeine Straßen im ländlichen und urbanen Bereich sowie Autobahnen
Beschreibung des Demonstrators	<p>Das Versuchsfahrzeug ist mit einer auf dem Dach integrierten Sensorbox ausgestattet. Im Projekt wurde das Kamera-System genutzt, welches aus insgesamt neun hochauflösenden Kameras besteht. Diese wurden gezielt rund um das Fahrzeug installiert, um eine vollständige 360-Grad-Rundumsicht zu ermöglichen. Jede Kamera verfügt über einen 5-Megapixel-Bildsensor und liefert Bildmaterial mit einer Auflösung von 2880 × 1860 Pixeln, was eine detaillierte Erfassung der Fahrzeugumgebung erlaubt.</p> 
Beschreibung der durchgeführten Versuche	Das Sensormessfahrzeug wurde im Rahmen des Projektes eingesetzt, um Kamera-Daten auf der A33 aufzuzeichnen, die zum Testen eines von dSPACE entwickelten kamerabasierten Perzeptionsalgorithmus mittels Data Replay genutzt wurden.

Tabelle 5: Demonstrator Inyo Leichtbau Shuttle

Name des Demonstrators	Inyo Leichtbau Shuttle
Verantwortlicher Partner	Technische Hochschule Augsburg


Typ des Demonstrators	Prototypischer Leichtbau Shuttle für automatisierte On-Demand Mobilität
Einsatzort des Demonstrators	Testfeld Mobilität
Beschreibung des Demonstrators	
Beschreibung der durchgeführten Versuche	Mit dem Inyo-Leichtbau-Shuttle wurden Integrations- und Funktionstests zur Validierung der Sensorik, Aktuatorik und Sicherheitsfunktionen durchgeführt. Ergänzend fanden Sensormessfahrten zur Fahrzeugmodell-Identifizierung sowie Versuche im Hybrid Testing Framework (HTF) zur Absicherung des Wahrnehmungs- und Steuerungsstacks statt.

Tabelle 6: Demonstrator Sensormessfahrzeug RAC-1

Name des Demonstrators	Sensormessfahrzeug RAC-1
Verantwortlicher Partner	RA Consulting GmbH
Typ des Demonstrators	Reales Fahrzeug auf Basis eines BMW i3
Einsatzort des Demonstrators	allgemeine Straßen im ländlichen und urbanen Bereich
Beschreibung des Demonstrators	Das Versuchsfahrzeug ist mit einer temporär auf dem Dach installierten Sensoreinheit ausgestattet. Im Projekt wurden sowohl die Positionierung, als auch LIDAR und Kameradaten verwendet. Zusätzlich ist eine Telematik-Einheit zur Erfassung von CAN- bzw. Diagnosedaten über die OBD-Schnittstelle des Fahrzeugs verbaut.

		
<p>Beschreibung der durchgeführten Versuche</p>	<p>Die erfassten Daten wurden als Referenzen für unterschiedliche Datenklassen im Hinblick auf Datenmenge, Sampling-, bzw. Frame-Rate und Skalierbarkeit und Echtzeit-Bezug verwendet. Abhängig von den konfigurierten Sensoren und den verfügbaren Verbindungseigenschaften wurden unterschiedliche Szenarien zur Skalierung der Übertragung getestet. Damit konnten einfache Validierungsszenarien erprobt werden, die aktuelle Messwerte aus dem Fahrzeug erfordern, wie z.B. Geschwindigkeiten, Motordaten, aber auch Beschleunigungen, Positionen, sowie Kameradaten aus den zusätzlichen Sensoren.</p>	

Tabelle 7: Demonstrator Sensormessfahrzeug RAC-2

Name des Demonstrators	Sensormessfahrzeug RAC-2
Verantwortlicher Partner	RA Consulting GmbH
Typ des Demonstrators	Reales Fahrzeug auf Basis eines VW-T6
Einsatzort des Demonstrators	allgemeine Straßen im ländlichen und urbanen Bereich
Beschreibung des Demonstrators	Das Versuchsfahrzeug ist mit einer temporär auf dem Dach installierten Sensoreinheit ausgestattet. Im Projekt wurden sowohl die Positionierung, als auch LIDAR und Kameradaten verwendet. Zusätzlich wurde eine mobile Starlink-Antenne verbaut, die auch eine Internetverbindung erlaubt, wenn sich das Fahrzeug in Bewegung befindet.

	
<p>Beschreibung der durchgeführten Versuche</p>	<p>Mit diesem Fahrzeug wurden analog zu den Untersuchungen mit dem Fahrzeug RAC-1 Vergleichsmessungen durchgeführt, die statt 5G eine Starlink-Verbindung genutzt haben. Durch die bessere Datenanbindung konnten z.B. auch Verkehrsszenarien erfasst, und damit auch der umgebende Verkehr einbezogen werden. Durch die Satelliten-gestützte Kommunikation waren auch datenintensive Validierungen, wie z.B. Video-Daten besser test- und abbildbar.</p>

Tabelle 8: Demonstrator Sensormessfahrzeug RAC-3

<p>Name des Demonstrators</p>	<p>Sensormessfahrzeug RAC-3</p>
<p>Verantwortlicher Partner</p>	<p>RA Consulting GmbH</p>
<p>Typ des Demonstrators</p>	<p>Reales autonomes Fahrzeug auf Basis eines NEOLIX</p>
<p>Einsatzort des Demonstrators</p>	<p>Ausschließlich nichtöffentliche Bereiche</p>
<p>Beschreibung des Demonstrators</p>	<p>Das Versuchsfahrzeug ist mit einem zu den anderen Fahrzeugen vergleichbaren Sensorset fix ausgestattet, d.h. es bietet ebenso LIDAR und Kamera-basierte Datenerfassung. Ebenso, wie die mobile Sensoreinheit, ist eine IMU in Kombination mit GPS zur genauen Positionierung vorhanden.</p>


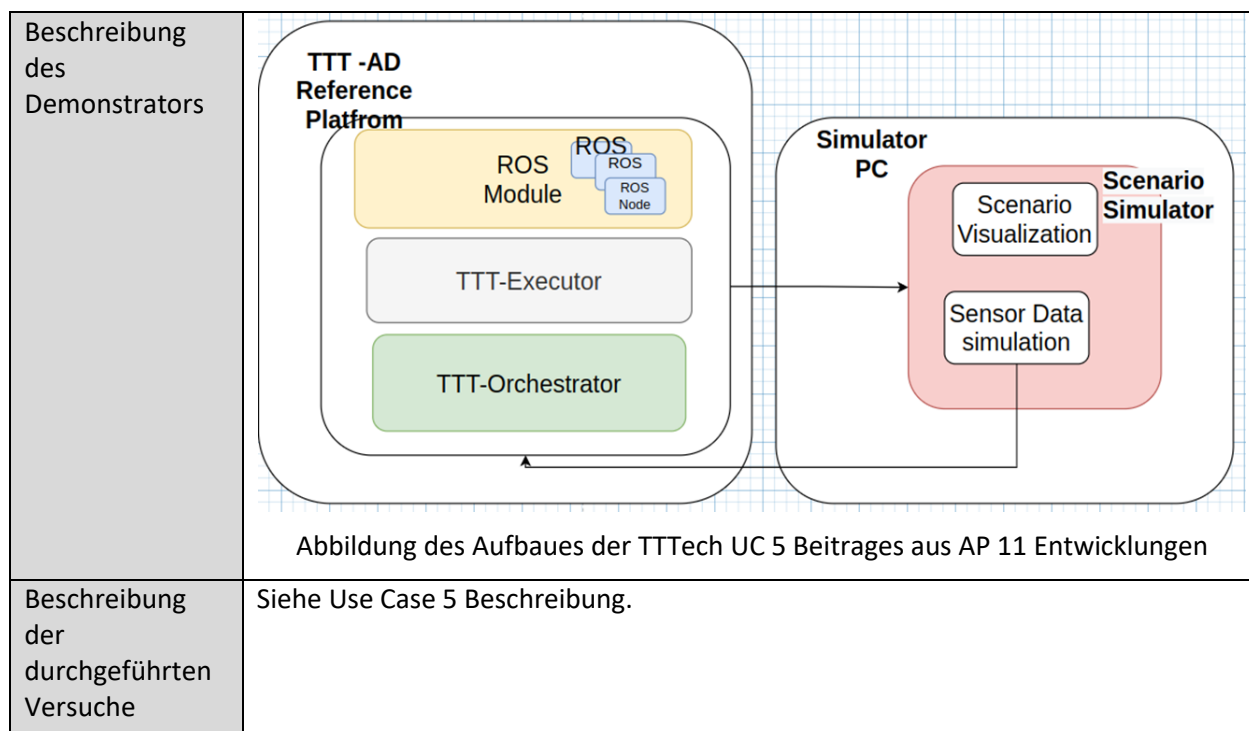
	 <table border="1" data-bbox="616 651 1278 904"> <thead> <tr> <th>PARAMETER TYPE</th> <th>PROJECTS</th> <th>INDICATORS</th> </tr> </thead> <tbody> <tr> <td rowspan="3">Mechanical Parameters</td> <td>Length * Width * Height [mm]</td> <td>2775*1010*1672</td> </tr> <tr> <td>Wheelbase [mm]</td> <td>1730</td> </tr> <tr> <td>Body Weight [kg]</td> <td>420</td> </tr> <tr> <td>Performance Parameters</td> <td>No-load Maximum Speed [km/h]</td> <td>20</td> </tr> <tr> <td rowspan="2">Control Parameters</td> <td>Control Mode</td> <td>Remote Control, Line Control</td> </tr> <tr> <td>Communication Interface</td> <td>CAN 2.0, LTE</td> </tr> </tbody> </table>	PARAMETER TYPE	PROJECTS	INDICATORS	Mechanical Parameters	Length * Width * Height [mm]	2775*1010*1672	Wheelbase [mm]	1730	Body Weight [kg]	420	Performance Parameters	No-load Maximum Speed [km/h]	20	Control Parameters	Control Mode	Remote Control, Line Control	Communication Interface	CAN 2.0, LTE
PARAMETER TYPE	PROJECTS	INDICATORS																	
Mechanical Parameters	Length * Width * Height [mm]	2775*1010*1672																	
	Wheelbase [mm]	1730																	
	Body Weight [kg]	420																	
Performance Parameters	No-load Maximum Speed [km/h]	20																	
Control Parameters	Control Mode	Remote Control, Line Control																	
	Communication Interface	CAN 2.0, LTE																	
Beschreibung der durchgeführten Versuche	<p>Zusätzlich zu den Tests mit den Fahrzeugen RAC-1 und RAC-2 konnten mit diesem Fahrzeug Echtzeit-Eingriffe in die Fahrfunktion getestet werden. Mit dem ROS-basierten Steuerungssystem im Fahrzeug konnte so z.B. ein Not-Halt nachgestellt werden. Dabei wird über das Dashboard ein Alert ausgelöst, der dann an das Fahrzeug übermittelt wird. Im Falle der Fahrzeuge mit Fahrer, erhält dieser über eine geeignete Anzeige eine Meldung zu diesem Alert, wo er diesen dann auch entsprechend bestätigen kann. Im Falle dieses autonomen Fahrzeugs konnte dieser Alert direkt zum Eingriff in die Fahrfunktion, wie z.B. zum Auslösen eines Anhalte-Manövers, genutzt werden.</p>																		

Tabelle 9: Demonstrator AD Referenzsystem und automatisches AD MW & Computing Test System

Name des Demonstrators	AD Referenzsystem und automatisches AD MW & Computing Test System
Verantwortlicher Partner	TTTech
Typ des Demonstrators	Prototypischer Laboraufbau als Ergebnis von AP 11
Einsatzort des Demonstrators	TTTech Labor



2.2 NUTZEN UND VERWERTBARKEIT

Im Fokus dieses Kapitels steht die Reflexion der Zusammensetzung des Konsortiums und der gewählten Arbeitsweise sowie der erzielten Ergebnisse. Darüber hinaus werden die Strategien zur Verbreitung der Projektergebnisse und deren praktische Nutzung analysiert. Das Projekt zeichnete sich durch seine hohe Komplexität und thematische Breite aus. Um die Ziele zu erreichen, war eine enge Zusammenarbeit zwischen wissenschaftlichen Einrichtungen und industriellen Partnern aus unterschiedlichsten Fachrichtungen unerlässlich. Die Herausforderungen, sowohl technologisch als auch organisatorisch, konnten nur durch ein interdisziplinär aufgestelltes Konsortium bewältigt werden. Das Projekt wäre ohne öffentliche Förderung nicht realisierbar gewesen. Die finanzielle Unterstützung ermöglichte es, Forschung und Entwicklung auf einem Niveau durchzuführen, das über die Möglichkeiten einzelner Unternehmen hinausgeht. Im Folgenden wird der Nutzen und die Verwertbarkeit der Projektpartner beschrieben.

DEKRA: Die gewonnenen Erkenntnisse der Datenbankanalysen inkl. der erarbeiteten Methoden kann direkt für Weiterentwicklungen von Prüfmethoden für die periodische technische Überwachung verwendet werden. Durch die Zusammenarbeit im Projekt konnte hier direkt eine Rückführung von Realdaten in die Fahrzeugentwicklung zur Auslegung von Zuverlässigkeit erzielt werden. Dies kann helfen die Fahrzeugkomponenten zuverlässiger auszulegen und sorgt damit nachhaltig für sicherere Systeme. Eine Übertragbarkeit auf andere Fahrzeugsysteme ist denkbar und könnte zugänglich gemacht werden. Die in UAP 4.4 erarbeiteten Diagnosedaten werden als Grundlage für zukünftige Prüfmethoden herangezogen und auch um gesetzliche Entwicklungen zu begleiten. Das erarbeitete Prüfmodell für eine zukünftige periodische technische Überwachung soll weiterentwickelt und in Einklang mit den rechtlichen Entwicklungen konkretisiert werden.

dSPACE: Aus Sicht von dSPACE liegt der Fokus künftig auf der Übertragbarkeit und Skalierbarkeit der entwickelten Ansätze. Es wird untersucht, inwiefern sich die im Projekt erarbeiteten Methoden und Erkenntnisse aus den einzelnen Use Cases auf weitere Anwendungs- und Geschäftsfälle adaptieren lassen. Ziel ist es, die entwickelten Lösungen nicht nur projektspezifisch, sondern auch branchenübergreifend nutzbar zu machen.

So müssen beispielsweise die statistische Modelle aus Use Case 1 weiter ausgebaut und genutzt werden, um die Sicherheit und Zuverlässigkeit von ADAS/AD zu gewährleisten. Sie helfen dabei, potenzielle Risiken frühzeitig zu identifizieren und zu bewerten, was für die Entwicklung und den Betrieb dieser Technologien von entscheidender Bedeutung ist. Die in Use Case 2 entwickelte Modellierung soll weiterentwickelt und auf zusätzliche Geschäftsfelder angepasst werden. Insbesondere könnte sich ein Anwendungskontext für Versicherer ergeben, der wetterbedingte regionale Faktoren und die Zuverlässigkeit der Fahrzeuge berücksichtigt. Ein weiterer Fokus liegt auf den Methoden zur Absicherung von automatisierten Fahrzeugen und ihrer Komponenten aus Use Case 3. Neben der Vehicle Dynamics Modell Validierung müssen auch Umgebungs- und Sensormodelle validiert werden. Dafür müssen geeignete Ansätze entwickelt und implementiert werden, um zur Glaubwürdigkeitsbewertung der virtuellen Toolkette beizutragen.

EMI: Fraunhofer EMI entwickelte durch das Projekt eine auf Rechenzeit optimierte Gesamtsicherheitsmodellierung für SAE Level 3 bis 5 Funktionen, die eine systematische Erweiterung von Zustandsräumen und Übergangsmoellen ermöglicht. Dies half, Lücken in der Nachweisführung für Entwicklung, Zulassung und Software-Updates effizient zu identifizieren. EMI plant, die Ergebnisse in die Lehre an Universitäten einzubringen und hatte im Laufe des Projekts 8 wissenschaftliche Veröffentlichungen, um die Sichtbarkeit des Projekts zu erhöhen, und betreute außerdem 6 Masterarbeiten. Zudem erwartet EMI thematisch weiterführende Förderprojekte und eventuell direkte Industriaufträge im Bereich der Zuverlässigkeitsanalyse.

IQZ: Das vom IQZ innerhalb von Use-Case 2 des Förderprojekts entwickelte Standalone-Tool "RT-CARS" lässt sich sowohl kurz- als auch langfristig direkt in Projekten verwerten. Die Möglichkeit auf Systemebene funktionspfad-abhängige E/E/PE-Architekturen zu modellieren und anschließend über Simulationsmethoden bzgl. Ihrer Zuverlässigkeits-, Funktionsverfügbarkeits- und Sicherheitseigenschaften in Form von quantitativen KPIs zu bewerten ist nach aktuellem Stand in der Funktionalität einzigartig. RT-CARS ist nicht branchenspezifisch und kann in allen technischen Disziplinen mit (teil-)redundanten Systemauslegungen verwendet werden. Der Einsatzbereich erstreckt sich über mehrere Phasen im PEP (Produktentwicklungsprozess) und kann sowohl für Design- als auch Validierungs- und Verifizierungs- sowie Homologationsthemen angewendet werden.

Die in innerhalb von Use-Case 1 entwickelte Möglichkeit zur rosbag-basierten nachträglichen Sensorsimulation lässt sich für beliebige MiL-Anwendungen (Model-In-The-Loop) adaptieren. Innovativ ist hierbei die Methodik der Fehlerinjektion statt der klassischen Sollfunktionssimulation. Dies ermöglicht Aussagen über die Robustheit der geprüften Anwendungen in Hinblick auf zu erwartende Störungen (z.B. Verschmutzung). Die Verwertbarkeit erfordert, anders als RT-CARS, einen klaren Anwendungsfall und eine individuelle Anpassung der Algorithmik, während RT-CARS universell einsetzbar ist.

JHP: Die in der Vorhabensbeschreibung genannten Verwertungsziele haben sich im Projektverlauf bestätigt. JHP konnte praxisnahe Methoden entwickeln, welche im Rahmen entsprechender Kundenanfragen aus der Industrie angewendet werden können. Softwarezuverlässigkeit ist ein wesentlicher Bestandteil der Gesamtzuverlässigkeit komplexer Systeme. Die im Bereich der KI-Perzeptionsalgorithmen entwickelten Methoden und Anwendungen sind auf jegliche KI-Softwareentwicklungsprojekte anwendbar und stellen für JHP eine gute Ausgangsbasis für erfolgreiche Industrieprojekte dar, da wir Lösungen nicht erst entwickeln müssen sondern schon haben.

Auch im Hinblick auf unsere Schulungsaktivitäten im Bereich Reliability Engineering können wir von den Erfahrungen und den Ergebnissen im RDV-Projekt profitieren. Unsere Schulungsmaterialien zum Thema "Software Reliability" können wir um relevante KI-Aspekte erweitern, um mit unseren Ausbildungen noch näher am aktuellen Stand der Technik zu sein und die Attraktivität unseres Schulungsangebotes weiter zu erhöhen.

LiangDao: Die von LiangDao entwickelte Cloud-Lösung ermöglicht eine skalierbare und DSGVO-konforme Speicherung, Verarbeitung und Analyse relevanter Fahrzeugdaten. Durch standardisierte Schnittstellen (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 von autonomem Fahren und GAIA-X, insbesondere für Daten, wie sie für den RDV-Ansatz benötigt werden. Darüber hinaus lässt sich die entwickelte Lösung leicht für andere Zielsetzungen optimieren, etwa für die Bereitstellung von Smart-City-Lösungen zur Verkehrsanalyse.

THA: Die im Projekt erzielten Ergebnisse werden ausschließlich wissenschaftlich verwertet. Sie bilden eine zentrale Grundlage für die weitere Forschung an hochautomatisierten Fahrfunktionen und sicherheitskritischen Systemen an der Technischen Hochschule Augsburg. Durch die erfolgreiche Integration und Inbetriebnahme des Inyo-Leichtbau-Shuttles wurde eine belastbare Forschungsplattform geschaffen, die künftig für experimentelle Untersuchungen und Validierungen im Testzentrum Mobilität Penzing eingesetzt wird.

Die im Rahmen der Sensormessfahrten gewonnenen Daten werden für die modellbasierte Identifizierung fahrzeugspezifischer Dynamikparameter und die Validierung von Regel- und Wahrnehmungsalgorithmen genutzt. Diese Erkenntnisse fließen unmittelbar in laufende wissenschaftliche Arbeiten und in das Nachfolgeprojekt NeMo.Bil ein, wo sie zur Weiterentwicklung der Sensorfusion, der Lokalisierung und der sicheren Steuerung modularer Fahrzeugkonzepte beitragen.

Das im Projekt entwickelte Hybrid Testing Framework (HTF) dient als methodische Basis für simulationsgestützte Sicherheitsanalysen und hybride Validierungsansätze. Es wird in zukünftigen Forschungsprojekten weiterverwendet und fortentwickelt, um die Lücke zwischen realer Fahrzeugprüfung und virtueller Absicherung zu schließen.

Darüber hinaus werden die gewonnenen Ergebnisse in die Lehre integriert, insbesondere in die Masterstudiengänge „Applied Research“ und „Data Science“. Ziel ist es, Studierenden und Forschenden praxisnahe Einblicke in die wissenschaftliche Entwicklung, Simulation und Validierung hochautomatisierter Fahrzeugsysteme zu vermitteln und so den Wissenstransfer in Forschung und Hochschullehre nachhaltig zu stärken.

TNM: TÜV NORD Mobilität hat im Rahmen des Verbundprojekts RDV seine Forschungsaktivitäten gezielt auf die Ziele des Förderprogramms ausgerichtet. Im Mittelpunkt der Arbeiten stand die Entwicklung von Test- und Prüfmethoden für hoch- und vollautomatisiertes Fahren.

Im Typgenehmigungsprozess sind die technischen Dienste unverzichtbar, da ihre neutrale Bewertung die Einhaltung der Vorschriften sicherstellt. Dadurch tragen sie wesentlich zur Verkehrssicherheit und zum Umweltschutz bei. Es ist daher unerlässlich, dass die Sachverständigen der technischen Dienste stets auf dem neuesten Stand der Technik sind. Nur so können Prüforganisationen die Genehmigungsvorschriften korrekt anwenden und zuverlässige Prüfkonzepte entwickeln, die die Sicherheit der Fahrzeuge bewerten. Deshalb ist eine enge Zusammenarbeit zwischen Prüforganisationen, Forschungsinstituten, Herstellern und Betreibern notwendig, um effektive Prüfkonzepte zu entwickeln.

Die Berücksichtigung sicherheitstechnischer Anforderungen und die Implementierung durchgängiger Sicherheitsprozesse über den gesamten Entwicklungs- und Produktionslebenszyklus hinweg sind entscheidend, um einen ausreichenden Technologiereifegrad bei der Entwicklung von hoch- und vollautomatisierten Fahrzeugen zu erreichen. Die Entwicklung sicherer und technisch ausgereifter Fahrzeuge ist ein wesentlicher Faktor für die Wettbewerbsfähigkeit des Standorts Deutschland.

Die Zusammenarbeit mit Betreibern, Herstellern und Forschungseinrichtungen im Projekt RDV war für TÜV NORD Mobilität von großer Bedeutung. Ein zentraler Aspekt für das Inverkehrbringen neuer Produkte ist der Nachweis ihrer Sicherheit. Dazu sind geeignete Prüf- und Genehmigungskonzepte sowie die technische Machbarkeit von entscheidender Bedeutung-

TTTech: Die Arbeiten im RDV Projekt sind für TTTech von entscheidender Bedeutung und ein wesentlicher Schritt weiter in Richtung SAE Level 4-5 hochautomatisiertes/autonomes Fahren. Die Beiträge mit dem Organic Computing haben nachgewiesen, dass Selbstheilungsmethoden funktionieren. Auch entsprechende SW Komponenten um die Lösungen von der Nutzung weniger teurer und weniger leistungsfähiger Controller stellen eine einmalige Gelegenheit dar die TTTech als high-tech Lieferanten am Markt zu bestätigen. TTTech wird nun nach RDV und unter Nutzung der Resultate aus RDV intensiv an der Weiterentwicklung zu Serienanwendungen arbeiten.

RAC: Neben der angestrebten Vermarktung im Bereich des RDV von hochautomatisierten und autonomen Fahrfunktionen sehen wir weitere Vermarktungschancen für eine innovative Kommunikations-Middle-Ware im Bereich der echtzeitnahen Remote Diagnose und Manipulationserkennung an Fahrzeugen, die im Fahrbetrieb sind. Die im Projekt erarbeiteten fortschrittlichen Konzepte für den TelTaKo-S können für die Ablösung einer älteren technisch veralteten Kommunikations-Middle-Ware der RA Consulting genutzt werden. Hierbei handelt es sich zwar um einen nicht Use-Case 4-nahen HAF-/AD-Anwendungsfall, aber die fortschrittliche Architektur des Systems ist natürlich auch für technische weniger anspruchsvolle Anwendungsfälle hervorragend geeignet. So soll auf Basis der Projektergebnisse und -erkenntnisse ein Datentransfer-Server für eine sehr hohe Anzahl an Datentransfers (aktuell 1 Mio. Messungen ca. 500.000 LKWs im Feld) mit geringeren Anforderungen an Latenzzeiten (hier im Sekundenbereich) das DTS NG (Daten Transfer Server Next Generation) entwickelt werden, um den zukünftig erhöhten Anforderungen an die Kommunikationsdienste zu genügen. Die aktuelle Gesetzgebung der EU, wie der EU-Data-Act und die aktuelle Initiative zu Anti-Tampering in der EU und das CTC-Programm in Kalifornien erhöhen erfreulicherweise die Verwertungschancen der Projektarbeiten in den kommenden Jahren in neuen Anwendungsbereichen deutlich.

2.3 BEKANNT GEWORDENER FORTSCHRITT

Am Ende der Projektlaufzeit waren mehrere Cloud-basierte Lösungen am Markt, 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.

Ein entscheidender Fortschritt hat sich in zweierlei Hinsicht betreffend der Ergebnisse aus AP 11, AD Referenzsystem und automatisches AD MW & Computing Test-System ergeben. Zum ersten haben wir einen Nachweis erarbeitet, dass sich „Organic Computing“ Methoden als Basis für „System Health“ Lösungen mit Selbstheilungsmechanismen auch lückenlos mit echtzeitfähigen Systemen eignen. Zusätzlich haben wir eine Lösung mit den Software-Paketen TTT-Executor und TTT-Orchestrator realisiert, die auch mit weniger leistungsstarken Controllern eine zuverlässige Funktion zur Verfügung stellen kann.

Auch bei der Standardisierung wurde das Thema Validierung im Allgemeinen aufgegriffen, insbesondere vor dem Hintergrund des Zusammenspiels unterschiedlicher relevanter Standards, die zum Einsatz kommen können. Bei der ASAM wurde nach einem Konzeptprojekt ab Oktober 2024 das Projekt TestSpecification gestartet, welches insbesondere das Ziel hat, das Zusammenspiel der ASAM-Standards ASAM ODS, ASAM OTX und ASAM XIL zu verbessern. Dabei werden über die RDV-Projektlaufzeit hinaus unter Leitung der RA Consulting GmbH und Beteiligung der dSPACE GmbH im Rahmen der ASAM-Arbeitsgruppe die zum Teil aus den Erkenntnissen der RDV Arbeiten stammenden Ergebnissen umgesetzt werden.

Gegen Ende des Projektes hat die EU-Kommission einen Vorschlag zur Überarbeitung der EU-Richtlinie 2014/45/EU veröffentlicht. Dieser beinhaltet für RDV betreffend begünstigende Inhalte. Für die periodische technische Überwachung (PTI) wird ein neuer Prüfpunkt 10 „elektronische Sicherheitssysteme“ mit aufgenommen. Unter diesem befinden sich Assistenzsysteme die verpflichtend geprüft werden sollen. Dieser Richtlinienentwurf ist aktuell in der Diskussion. Das Gesetzgebungsverfahren der EU sieht vor, dass neben der EU-Kommission (Richtlinien-Vorlage) auch der EU-Rat und das EU-Parlament zustimmen. Ein grundsätzliches „Inkrafttreten“ könnte ggf. im Jahre 2029 erfolgen.

2.4 VERÖFFENTLICHUNG DER ERGEBNISSE

- V1 Chimbalkar, Udit (2025): Numerical and Monte Carlo Modelling of Scaling Markov Models to Control State Space Explosion. Master Thesis. RWU, Hochschule Ravensburg-Weingarten.
- V2 Dhanani, Mayur (2023): Failure and Recovery Models of Autonomous Vehicles Subsystems for Markov Safety Simulation. Master Thesis. Hochschule Nordhausen.
- V3 Häring, Ivo; Mopuru, Sunil Kumar Reddy; Walz, Teo Puig; Dhanani, Mayur; Sandela, Nikhilesh; Finger, Jörg et al. (2023a): Overall Markov Diagram Design and Simulation Example for Scalable Safety Analysis of Autonomous Vehicles. In: Mário P. Brito, Terje Aven, Piero Baraldi, Marko Čepin und Enrico Zio (Hg.): Proceeding of the 33rd European Safety and Reliability Conference. 33rd European Safety and Reliability Conference, 03.09.2023 - 07.09.2023. Singapore: Research Publishing Services, S. 2261–2268.
- V4 Häring, Ivo; Padariya, Rachana; Vogelbacher, Georg; Höflinger, Fabian; Richter, Alexander; Finger, Jörg et al. (2024a): Failure And Repair Rates For Lane Detection For Safety Assessment Of Autonomous Driving From CARLA Simulation. In: Krzysztof Kołowrocki und Kazimierz T. Kosmowski (Hg.): Advances in Reliability, Safety and Security. Part 10 Cybersecurity and Functional Safety in Hazardous System & Research Challenges Concerning Sustainability, Safety and Security. ESREL 2024. Cracow, Poland, 23-27 June 2024. Gdynia: Polish Safety and Reliability Association, S. 77–86. Online verfügbar unter <https://esrel2024.com/wp-content/uploads/articles/part10/failure-and-repair-rates-for-lane-detection-for-safety-assessment-of-autonomous-driving-from-carla-simulation.pdf>, zuletzt geprüft am 25.11.2025.
- V5 Häring, Ivo; Sandela, Nikhilesh; Padariya, Rachana; Vogelbacher, Georg; Höflinger, Fabian; Richter, Alexander et al. (2024b): Failure Rates Per Time For Autonomous Driving Safety Assessment From CARLA Simulation. In: Krzysztof Kołowrocki und Kazimierz T. Kosmowski (Hg.): Advances in Reliability, Safety and Security. Part 10 Cybersecurity and Functional Safety in Hazardous System & Research Challenges Concerning Sustainability, Safety and Security. ESREL 2024. Cracow, Poland, 23-27 June 2024. Gdynia: Polish Safety and Reliability Association, S. 87–96. Online verfügbar unter <https://esrel2024.com/wp-content/uploads/articles/part10/failure-rates-per-time-for-autonomous-driving-safety-assessment-from-carla-simulation.pdf>, zuletzt geprüft am 25.11.2025.

- V6 Häring, Ivo; Sandela, Nikhilesh; Walz, Teo Puig; Vogelbacher, Georg; Richter, Alexander; Jain, Aishvarya Kumar et al. (2023b): Dynamically Resolving and Abstracting Markov Models for System Resilience Analysis. In: Mário P. Brito, Terje Aven, Piero Baraldi, Marko Čepin und Enrico Zio (Hg.): Proceeding of the 33rd European Safety and Reliability Conference. 33rd European Safety and Reliability Conference, 03.09.2023 - 07.09.2023. Singapore: Research Publishing Services, S. 241–248.
- V7 Häring, Ivo; Satsrisakul, Yupak; Finger, Jörg; Vogelbacher, Georg; Köpke, Corinna; Höflinger, Fabian; Gelhausen, Patrick (2022): Advanced Markov Modeling and Simulation for Safety Analysis of Autonomous Driving Functions up to SAE 5 for Development, Approval and Main Inspection. In Maria Chiara Leva, Edoardo Patelli, Luca Podofillini, Simon Wilson (Eds): Proceedings of the 32nd European Safety and Reliability Conference. ESREL 2022. 28th August – 1st September 2022, Dublin, Ireland. Singapore: Research Publishing Services, pp. 104–111. Online verfügbar unter <https://www.rpsonline.com.sg/proceedings/esrel2022/html/R03-02-012.xml>
- V8 Häring, Ivo; Vogelbacher, Georg; Richter, Alexander; Finger, Jörg; Chimbalkar, Udit; Jain, Aishvarya et al. (2025): Scaling sparse Markov model of autonomous vehicle functions including environment, driver and traffic conditions for reliability and safety assessment. eingereicht. In: Special Issue Journal Paper Risk Analysis.
- V9 Horeis, Timo Frederik; Heinrich, Johannes; Plinke, Fabian (2022): A Self-Adapting Reconfiguration Process for The Failure Management of Highly Automated Vehicles. In: Maria Chiara Leva, Edoardo Patelli, Luca Podofillini und Simon Wilson (Hg.): Proceeding of the 32nd European Safety and Reliability Conference. 32nd European Safety and Reliability Conference, 28.08.2022 - 01.09.2022. Singapore: Research Publishing Services, S. 838–845.
- V10 Horeis, Timo Frederik; Rinaldo, Rhea C. (2023) Towards Verification of Self-Healing for Autonomous Vehicles. In: Mário P. Brito, Terje Aven, Piero Baraldi, Marko Čepin und Enrico Zio (Hg.): Proceeding of the 33rd European Safety and Reliability Conference. 33rd European Safety and Reliability Conference, 03.09.2023 - 07.09.2023. Singapore: Research Publishing Services, S. 334–341.
- V11 Jäger, Patrick; Harlammert, Nora; De Candido, Oliver; Yildiz, Gökay (2025): Vom Unsichtbaren zum Messbaren. In HANSER automotive Ausgabe 4/2025 Seite 22-25.
- V12 Jäger, Patrick; Krolo, Melani, Jäger, Ute (2025): Approach for a reliability proof of autonomous vehicles compared to human drivers through real-world road tests. In Proceedings of the 35th European Safety and Reliability Conference (ESREL 2025), 15.-19.06.2025, Stavanger, Norway.
- V13 Jain, Aishvarya Kumar; Srivastava, Kushal; Walz, Teo Puig; Häring, Ivo; Vogelbacher, Georg; Höflinger, Fabian; Finger, Jörg (2023): Deep Behavioral Replication of Markov Models for Autonomous Cars using Neural Networks. In: Mário P. Brito, Terje Aven, Piero Baraldi, Marko Čepin und Enrico Zio (Hg.): Proceeding of the 33rd European Safety and Reliability Conference. 33rd European Safety and Reliability Conference, 03.09.2023 - 07.09.2023. Singapore: Research Publishing Services, S. 3074–3079. Online verfügbar unter <https://rpsonline.com.sg/proceedings/esrel2023/html/P484.html>, zuletzt geprüft am 25.11.2025.
- V14 Mopuru, Sunil Kumar Reddy (2023): Safety analysis of autonomous driving by Markov modeling with focus on hardware architectures. Master Thesis. Hochschule Bremerhaven.
- V15 Nelluri, Varun Sai (2025): Behaviour replication of Markov chains using Deep learning for reliability analysis of autonomous cars. Master Thesis. Albert-Ludwigs-Universität Freiburg.

- V16 Padariya, Rachana (2024): Failure rate estimation of lane detection from CARLA Simulation for Markov Model safety assessment of autonomous driving functions. Master Thesis. WHZ Westsächsische Hochschule Zwickau.
- V17 Richter, Alexander; Walz, Teo Puig; Dhanani, Mayur; Häring, Ivo; Vogelbacher, Georg; Höflinger, Fabian et al. (2023): Components and Their Failure Rates in Autonomous Driving. In: Mário P. Brito, Terje Aven, Piero Baraldi, Marko Čepin und Enrico Zio (Hg.): Proceeding of the 33rd European Safety and Reliability Conference. 33rd European Safety and Reliability Conference, 03.09.2023 - 07.09.2023. Singapore: Research Publishing Services, S. 233–240.
- V18 Rupalla, Armin; Kotschenreuther, Thomas (2024): From Telematics to Teleoperation. In: ASAM International Conference 2024.
- V19 Rupalla, Armin; Kotschenreuther, Thomas; Dr. Hantschel, Frank (2024): Von der Telemetrie zu Teleoperation - Anforderungen und Machbarkeit. In: 17. Tagung „Diagnose in mechatronischen Fahrzeugsystemen“ Dresden, 14.05.2024-15.05.2024.
- V20 Sandela, Nikhilesh (2023): Safety and Reliability Analysis of Autonomous Driving using Markov Modeling and Deep Learning. Master Thesis. Otto von Guericke Universität Magdeburg
- V21 Walz, Teo Puig; Mopuru, Sunil Kumar Reddy; Vogelbacher, Georg; Richter, Alexander; Höflinger, Fabian; Häring, Ivo et al. (2023): Markov Modelling for Autonomous Vehicle Safety Assessment: Numerical Modularization to Avoid System State-Explosion. In: 2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC). Bilbao, Spain, 24-28 September 2023: IEEE, S. 4881–4886. Online verfügbar unter <https://ieeexplore.ieee.org/document/10421943>, zuletzt geprüft am 25.11.2025.

3 LITERATURVERZEICHNIS

Abdulkhaleq, Asim; Lammering, Daniel; Wagner, Stefan; Röder, Jürgen; Balbierer, Norbert; Ramsauer, Ludwig et al. (2017): A Systematic Approach Based on STPA for Developing a Dependable Architecture for Fully Automated Driving Vehicles. In: *Procedia Engineering* 179, S. 41–51. DOI: 10.1016/j.proeng.2017.03.094.

Altabbakh, Hanan; AlKazimi, Mohammad A.; Murray, Susan; Grantham, Katie (2014): STAMP – Holistic system safety approach or just another risk model? In: *Journal of Loss Prevention in the Process Industries* 32, S. 109–119. DOI: 10.1016/j.jlp.2014.07.010.

Aljohani, Tawfiq M.; Ebrahim, Ahmed; Mohammed, Osama (2021): 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. DOI: 10.1016/j.epsr.2020.106962.

Bagschik, Gerrit; Stolte, Torben; Maurer, Markus (2017): Safety Analysis Based on Systems Theory Applied to an Unmanned Protective Vehicle. In: *Procedia Engineering* 179, S. 61–71. DOI: 10.1016/j.proeng.2017.03.096.

Bock, Thomas; Maurer, Markus; Farber, Georg (2007): Validation of the Vehicle in the Loop (VIL); A milestone for the simulation of driver assistance systems. 2007 IEEE Intelligent Vehicles Symposium, Istanbul, S. 612–617. DOI: 10.1109/IVS.2007.4290183.

Bock, Thomas; Maurer, Markus; Meel, Franciscus; Müller, Thomas (2008): Vehicle in the Loop. In: *ATZ Automobiltech Z* 110 (1), S. 10–16. DOI: 10.1007/BF03221943.

Böde, E; Fränzle, M; Kramer, B; van der Maelen, S (2019): Identifikation von Automationsrisiken hochautomatischer Fahrfunktionen in PEGASUS. In: AAET (Hg.): *Proceedings AAET Automatisiertes und vernetztes Fahren 2019*. Braunschweig, Germany, 06.-07.02.2019: ITS mobility e. V., S. 315–329. Online verfügbar unter https://www.offis.de/uploads/tx_offisdata/1550238544-Identifikation_von_Automationsrisiken_hochautomatisierter_Fahrfunktionen_in_PEGASUS_Preprint.pdf, zuletzt geprüft am 09.10.2020.

Bondesson, Carl (2018): Modelling of safety concepts for autonomous vehicles using semi-Markov models. Examensarbeit. Upsala Universitet, Teknisk-naturvetenskaplig fakultet UTH-enheten. Online verfügbar unter <https://pdfs.semanticscholar.org/22fb/3be001a8539da6b9dea8963337eef98eda2.pdf>.

Bürker, Matthias; Kramer, Birte; Böde, Eckard; van der Maelen, Sebastian; Fränzle, Martin (2019): Identifikation von Automationsrisiken hochautomatischer Fahrfunktionen in PEGASUS. In: *AAET Automatisiertes und vernetztes Fahren: ITS mobility e. V*, S. 315–329.

Cherfi, Abraham; Leeman, Michel; Meurville, Florent; Rauzy, Antoine (2014): Modeling automotive safety mechanisms: A Markovian approach. In: *Reliability Engineering & System Safety* 130, S. 42–49. DOI: 10.1016/j.res.2014.04.013.

Ebner, Christian; Gorelik, Kirill; Zimmermann, Armin (2020): Model-Based Dependability Analysis of Fail-Operational Electric Drivetrains. In: *IEEE/ASME International Conference on Advanced Intelligent Mechatronics, AIM 2020*, Boston, MA, USA, July 6-9, 2020: IEEE, S. 256–263.

Ericson, Clifton (2005): *Hazard Analysis Techniques for System Safety*: Wiley.

Fragapane, Giuseppe; Koster, René de; Sgarbossa, Fabio; Strandhagen, Jan Ola (2021): Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda. In *European Journal of Operational Research* 294 (2), pp. 405–426. DOI: 10.1016/j.ejor.2021.01.019.

Gabas, Roland (2020): Verwendung von Systemanalysemethoden im BMWi-Projekt V&V Methoden, 13.10.2020. E-Mail an Ivo Häring.

Gheraibia, Youcef; Kabir, Sohag; Djafri, Khaoula; Krimou, Habiba (2018): An Overview of the Approaches for Automotive Safety Integrity Levels Allocation. In: J Fail. Anal. and Preven. 18 (3), S. 707–720. DOI: 10.1007/s11668-018-0466-9.

Gomes, Adriano; Mota, Alexandre; Sampaio, Augusto; Ferri, Felipe; Watanabe, Edson (2012): Constructive model-based analysis for safety assessment. In: Int J Softw Tools Technol Transfer 14 (6), S. 673–702. DOI: 10.1007/s10009-012-0238-x.

Heinrich, J; Plinke, F; Hausschild, J (2017): State-based safety and availability analysis of automated driving functions using Monte Carlo simulation: CRC Press, S. 1975–1982.

Huang, WuLing; Wang, Kunfeng; Lv, Yisheng; Zhu, FengHua (2016): Autonomous vehicles testing methods review. 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), Rio de Janeiro, S. 163–168. DOI: 10.1109/ITSC.2016.7795548.

Kaalen, Stefan (2019): Semi-Markov processes for calculating the safety of autonomous vehicles. Degree project in mathematics, second cycle. Stockholm

Kaalen, Stefan; Nyberg, Mattias; Bondesson, Carl (2019): Tool-Supported Dependability Analysis of Semi-Markov Processes with Application to Autonomous Driving. In: 2019 4th International Conference on System Reliability and Safety (ICSRS). 2019 4th International Conference on System Reliability and Safety (ICSRS). Rome, Italy, 20.11.2019 - 22.11.2019: IEEE, pp. 126–135.

Knoop, Steffen (2020): Verwendung von Systemanalysemethoden wie FMEA, FTA, Markov- und Petri-Netze im BMWi-Projekt 3F, 07.10.2020. E-Mail an Ivo Häring.

Loh, Silke; Mock, Michael (2020): 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. Online verfügbar unter <https://www.iais.fraunhofer.de/de/presse/presseinformationen/presseinformationen-2020/presseinformation-200526.html>, zuletzt aktualisiert am 26.05.2020, zuletzt geprüft am 13.10.2020.

Macher, Georg; Armengaud, Eric; Brenner, Eugen; Kreiner, Christian (2016): Threat and Risk Assessment Methodologies in the Automotive Domain. In: Procedia Computer Science 83, S. 1288–1294. DOI: 10.1016/j.procs.2016.04.268.

Mock, Michael (2020): Verwendung von analytischen Systemanalysemethoden im BMWi-Projekt KI-Absicherung, 22.10.2020. E-Mail an Ivo Häring.

Mosebach, Henning (2020): Verwendung von analytischen Systemanalysemethoden im BMWi-Projekt Set Level 4 to 5, 13.10.2020. Email an Ivo Häring.

Nyberg, M. (2018): Safety analysis of autonomous driving using semi-Markov processes: Taylor and Francis Group, S. 781–788. Online verfügbar unter <https://doi.org/10.1201/9781351174664>, <https://www.taylorfrancis.com/books/e/9781351174664>, zuletzt geprüft am 17.10.2019.

PEGASUS (2020): Projekt zur Etablierung von generell akzeptierten Gütekriterien, Werkzeugen und Methoden sowie Szenarien und Situationen zur Freigabe hochautomatisierter Fahrfunktionen. Schlussbericht für das BMWi Gesamtprojekt PEGASUS. Online verfügbar unter https://www.pegasusprojekt.de/files/tmpl/pdf/PEGASUS_Abschlussbericht_Gesamtprojekt.PDF, zuletzt geprüft am 14.10.2020.

Plötzwich, Florian (2020a): Projekt arbeitet an rechtssicherer Freigabe autonomer Autos. Projektstart V&V Methoden. Hg. v. SpringerProfessional. Online verfügbar unter

<https://www.springerprofessional.de/automatisiertes-fahren/funktionale-sicherheit/projekt-arbeitet-an-rechtssicherer-freigabe-autonom-autos/17042454>, zuletzt aktualisiert am 07.08.2020, zuletzt geprüft am 14.10.2020.

Plötzwich, Florian (2020b): Verwendung von analytischen Systemanalysemethoden im BMWi-Projekt V&V Methoden, 09.10.2020. E-Mail an Ivo Häring.

Reich, Jan; Nuffer, Jürgen (2020): Verwendung von Systemanalysemethoden im Projekt BMWi-V&V Methoden, 16.10.2020 an Ivo Häring. E-Mail.

ISO 20730-1 (2021): Road vehicles — Vehicle interface for electronic Periodic Technical Inspection (ePTI) Part 1: Application and communication requirements

ISO 20730-3 (2021): Road vehicles — Vehicle interface for electronic Periodic Technical Inspection (ePTI) Part 3: Data definitions

ISO 26262 Parts 1 to 12 Ed. 2, 2018-12: Road vehicles - Functional safety. Online verfügbar unter <https://www.iso.org/standard/68383.html>.

ISO/PAS 21448 2019, 2019-01: Road vehicles — Safety of the intended functionality, SOTIF. Online verfügbar unter <https://www.iso.org/standard/70939.html>, zuletzt geprüft am 21.09.2020.

Papadopoulos, Chrissoleon T.; Li, Jingshan; O'Kelly, Michael E.J. (2019): A classification and review of timed Markov models of manufacturing systems. In *Computers & Industrial Engineering* 128 (12), pp. 219–244. DOI: 10.1016/j.cie.2018.12.019.

Rosique, Francisca; Navarro, Pedro J.; Fernández, Carlos; Padilla, Antonio (2019): A Systematic Review of Perception System and Simulators for Autonomous Vehicles Research. In: *Sensors (Basel, Switzerland)* 19 (3). DOI: 10.3390/s19030648.

Sabaliauskaite, G; Shen, L; cui, J (2018): 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. Online verfügbar unter http://www.iariajournals.org/security/sec_v11_n12_2018_paged.pdf, zuletzt geprüft am 09.10.2020.

Satsrisakul, Yupak (2018): Quantitative probabilistic safety assessment of autonomous car functions with Markov models. Master Thesis. Universität Freiburg, Freiburg. INATECH.

Steinger, Udo (2020): Verwerwendung von analytischen Systemanalysemethoden im BMWi-Projekt PEGASUS aus Sicht des TÜV Süd: HA, FMEXA, FTA, Markov- und Petrinetze, 10.10.2020. Telefonat mit Ivo Häring.

Steinle, M.; Menzel, T. (2020): SET Level 4 to 5. Online verfügbar unter <https://www.ifr.ing.tu-bs.de/de/ag-elektronische-fahrzeugsysteme/forschung/set-level-4to5/>, zuletzt geprüft am 14.10.2020.

Stoewhase, Jens (2020): Bosch – Automatisiertes Fahren im Niedergeschwindigkeitsbereich. Hg. v. intellicar.de, autonomous, shared & connected mobility. Online verfügbar unter <https://intellicar.de/tests-and-research/bosch-automatisiertes-fahren-im-niedergeschwindigkeitsbereich/>, zuletzt aktualisiert am 03.04.2020, zuletzt geprüft am 13.10.2020.

Talebberrouane, Mohammed; Khan, Faisal; Lounis, Zoubida (2016): 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. DOI: 10.1016/j.jlp.2016.09.007.

Werwitzke, Cora (2020): Bosch: Wie autonome Shuttles Störungen selbst bewältigen. Hg. v. Branchendienst für Elektromobilität electrive.net. Online verfügbar unter <https://www.electrive.net/2020/04/05/bosch-wie-autonome-shuttles-stoerungen-selbst-bewaeltigen/>, zuletzt aktualisiert am 05.04.2020, zuletzt geprüft am 13.10.2020.

Winkle, Thomas (2016): Development and Approval of Automated Vehicles: Considerations of Technical, Legal, and Economic Risks. In: Markus Maurer, Barbara Lenz, Hermann Winner und J. Christian Gerdes (Hg.): Autonomous Driving: Technical, Legal and Social Aspects. s.l.: Springer, S. 589–618.

Yevkin, O. (2016): 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.