


ASIMOV

EUREKA Cluster AI 2020 Call Project ASIMOV:
AI training using Simulated Instruments for Machine
Optimization and Verification



Abschlussbericht

Förderkennzeichen: 01IS21022A-G

29.11.2024

Beteiligte Partner

Partnername	Abkürzung
AVL Deutschland GmbH	AVL
DLR e.V.	DLR
LiangDao GmbH	LiangDao
NorCom Information Technology GmbH & Co. KGaA	NorCom
OFFIS e.V. – Institut für Informatik	OFFIS
RA Consulting GmbH	RAC
TrianGraphics GmbH	TG

sowie weitere elf europäische Partner aus drei Ländern (siehe Anhang A). Aufgrund der nicht erfolgten Mittelbereitstellung für das finnische Konsortium sind die Arbeit dieses Konsortiums an ihrem Anwendungsfall, sowie den anderen methodischen Tasks, bis zum Ausscheiden am 05.07.2022 nur von geringem Umfang durchgeführt worden. Die Beiträge des finnischen Konsortiums wurden in den erfolgten Reports und Deliverables nur begrenzt dokumentiert. Auch wird im folgenden Bericht nur vom niederländischen und deutschen Konsortium und deren Anwendungsfällen sowie Arbeiten in den jeweiligen Tasks berichtet, sofern dies nicht anders angegeben ist.

Ansprechpartner

Dr. André Bolles (DLR)

Autor:innen

Niklas Braun (AVL)
Elias Modrakowski (DLR)
Dr. Andreas Eich (LiangDao)
Lukas Schmidt (Norcom)
Thomas Kotschenreuther (RAC)
Sebastian Moritz (TG)

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 01IS21022A-G gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autor:innen.

Inhalt

Beteiligte Partner	2
1 KURZBERICHT	4
1.1 Aufgabenstellung.....	4
1.2 Planung und Ablauf des Vorhabens	4
1.3 Wissenschaftlicher und technischer Stand vor Beginn des Projekts.....	4
1.4 Wesentliche Ergebnisse	5
1.4.1 Aufbau einer automatisierten Toolkette zum Testen autonomer Fahrzeuge	5
1.4.2 Parameterbasierte Variation der 3D Umgebung	5
1.4.3 Modulare Gesamtarchitektur für digitalen Zwilling.....	5
1.4.4 Aufbau eines Twinning Demonstrators für Kameramodelle.....	5
1.5 Zusammenarbeit mit anderen Stellen.....	5
2 EINGEHENDE DARSTELLUNG	6
2.1 Verwendung der Zuwendung und erzielte Ergebnisse	7
2.1.1 OFFIS e.V. (OFFIS)	7
2.1.2 AVL.....	10
2.1.3 DLR e.V.	14
2.1.4 LiangDao.....	17
2.1.5 NorCom	20
2.1.6 RAC	21
2.1.7 TrianGraphics.....	24
2.2 Zahlenmäßiger Nachweis	26
2.3 Notwendigkeit der Zuwendung.....	26
2.4 Voraussichtlicher Nutzen, insbesondere Verwertbarkeit der Ergebnisse	27
2.5 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen.....	28
2.6 Veröffentlichungen.....	28
Anhang A. Liste aller ASIMOV Partner	32
Anhang B. Liste aller Projektergebnisse (Deliverables)	33

1 KURZBERICHT

1.1 Aufgabenstellung

Cyber-physische High-Tech-Systeme (CPS) spielen in unserer Gesellschaft eine immer wichtigere Rolle. Die Sicherstellung einer optimalen Funktionalität erfordert hier meist komplexe Konfigurations- und Optimierungsvorgänge, die in der Regel von Experten mit tiefgreifender Erfahrung vorgenommen werden. Der Einsatz von Expert:innen für solche Aufgaben ist dabei mit erheblichen Nachteilen (Verfügbarkeit und Reproduzierbarkeit) verbunden. Im Projekt ASIMOV (AI training using Simulated Instruments for Machine Optimization and Verification) wurde untersucht, wie eine künstliche Intelligenz (KI) einen digitalen Zwilling (im englischen „Digital Twin“, DT) eines physischen Systems gefahrlos im virtuellen Raum konfigurieren/kalibrieren/optimieren kann und wie sich die Ergebnisse dieses Prozesses auf das physische System übertragen lassen.

Im Kontext des deutschen Teilprojektes wurde das Ziel verfolgt, die Entwicklung und Erprobung hochautomatisierter Nutzfahrzeuge mit Hilfe von KI zu beschleunigen. Anhand eines von der AVL eingebrachten Anwendungsfalls „Unmanned Utility Vehicle“ (UUV) wurden die folgenden Fragen untersucht:

- Wie kann KI gefahrlos genutzt werden, um eine optimierte Konfiguration / ein optimiertes Setup des zu entwickelnden Systems zu erhalten?
- Wie können mithilfe von KI und DT gefahrlos auch kritische Anwendungsfälle eines unbemannten Nutzfahrzeugs untersucht werden und zur späteren Sicherheit des Gesamtsystems beitragen?
- Wie können die im virtuellen Raum erzielten, KI-basierten Ergebnisse auf das physische System übertragen werden?

1.2 Planung und Ablauf des Vorhabens

Das Projekt gliederte sich in fünf Arbeitspakete (WP), die sich zentral um die zwei in **WP1** betrachteten Anwendungsfälle „Elektronenmikroskop“ (Niederlande), und „Hochautomatisiertes Nutzfahrzeug“ (Deutschland) drehten. Hierzu gab es drei methodische Arbeitspakete. **WP2** betrachtete die Entwicklung valider DTs von physischen Systemen, um sie für das KI-Training und für die KI-basierte Optimierung der Systemkonfigurationen nutzen zu können. In diesem WP beleuchtete das deutsche Konsortium insb. Fragestellungen zur Entwicklung, Aufbau und Validität der DTs. **WP3** beschäftigte sich mit dem Training von KI mithilfe von DTs. Hier wurden Fragestellungen zu Anforderungen an das KI-System, Eignung unterschiedlicher Algorithmen und Validität der KI-Systeme adressiert. Die Übertragbarkeit der virtuellen Ergebnisse auf physische Systeme wurde in **WP4** untersucht, wobei das deutsche Konsortium besonders auf Abweichungsanalysen für den Automobilanwendungsfall fokussiert war. An **WP5** beteiligte sich das deutsche Konsortium schließlich dahingehend, die in Deutschland erzielten Ergebnisse zu verwerten und Anderen, ggf. bekannt/zugänglich zu machen.

Das ASIMOV-Projekt war auf eine dreijährige Laufzeit angelegt. Der technische Fortschritt wurde jeweils zum Ende jedes Projektjahres berichtet und vorgestellt (Yearly ITEA Review). Durch die ITEA Project Progress Reports (M8, M14, M20, M26, M33) wurde der Projektfortschritt zusätzlich dokumentiert. Insgesamt wurden durch die inkrementelle Vorgehensweise (drei Iterationen) schnell vorzeigbare Ergebnisse (Proof-of-Concepts) erzielt.

1.3 Wissenschaftlicher und technischer Stand vor Beginn des Projekts

Das ASIMOV-Projekt fokussierte sich auf zwei Bereiche: KI-basierte Optimierung und DTs. Während KI zur Optimierung von Prozessen bereits etabliert ist, stellt der Einsatz in sicherheitskritischen industriellen Systemen eine besondere Herausforderung dar. DTs sind virtuelle Darstellungen tatsächlicher, in

Betrieb befindlicher CPS¹. Sie ermöglichen Unternehmen, einen vollständigen digitalen Fußabdruck ihrer Produkte über den kompletten Produktlebenszyklus zu erhalten. Das Konzept fand seinen Weg in die Industrie aufgrund der jüngsten technologischen Fortschritte². Das **Trainieren von KI** wird oft durch den Mangel an großen Mengen hoch-qualitativer Trainingsdaten eingeschränkt, die erforderlich sind, um das Anwendungssystemverhalten ausreichend zu erlernen. Mit einer akkuraten virtuellen Umgebung können diese Mengen an synthetischen Daten erzeugt werden.

1.4 Wesentliche Ergebnisse

Im Rahmen des Gesamtvorhabens wurden die folgenden wesentlichen Ergebnisse erzielt. Details können den Partnerberichten in Kapitel 2 entnommen werden.

1.4.1 Aufbau einer automatisierten Toolkette zum Testen autonomer Fahrzeuge

Ein entscheidender Baustein für die Erfüllung des Gesamtvorhabens war der Aufbau einer automatisierten Toolkette zur Variation, Ausführung und Bewertung von Testszenarien für ein autonomes Fahrzeug im urbanen Umfeld. Hierzu wurden mehrere Tools erfolgreich aneinander angebunden. Fahrdynamiksimulation, 3D Umgebungssimulation für Sensormodelle, sowie ein Modul zur Bewertung der Kritikalität und Erstellung der Szenarien wurden in einen Gesamtprozess integriert.

1.4.2 Parameterbasierte Variation der 3D Umgebung

Entscheidend für die Optimierung der Verkehrsszenarien ist neben der Beschreibung der Verkehrssituation (üblicherweise Gegenstand von Parametervariation) auch die 3D Umgebung. Im Gesamtvorhaben wurde diese parametrisiert und mittels verschiedener Methoden optimiert. Hierbei wurden exemplarisch Bäume, Schilder, Straßenbeläge, aber auch die Detailtiefe von Objekten variiert, um den Einfluss auf die Kritikalität untersuchen zu können.

1.4.3 Modulare Gesamtarchitektur für digitalen Zwilling

Beim Aufbau des DTs des Fahrzeugs und der Umgebung wurde ein modularer Ansatz gewählt, der es Fachteams mit unterschiedlichen Kompetenzen ermöglicht, unabhängig voneinander zu arbeiten und so eine unternehmensübergreifende Entwicklung zu fördern. Diese Architektur konnte auch auf Beispiele anderer Domänen angewendet werden.

1.4.4 Aufbau eines Twinning Demonstrators für Kameramodelle

Die Anpassung sensorspezifischer Merkmale eines DT an die Realität spielt bei der aussagekräftigen Simulation von Verkehrsszenarien eine wichtige Rolle. Um diesen Abgleich automatisiert auszuführen, wurde ein Demonstrator entwickelt, der das ideale Kamerabild der Simulation mittels Bildverarbeitung modifiziert, um das Resultat an die Erscheinung des realen Kamerabildes anzupassen.

1.5 Zusammenarbeit mit anderen Stellen

Im Rahmen des Projektes arbeitete das deutsche Teilkonsortium eng mit Industrie- und Forschungspartnern des internationalen Projektkonsortiums (Niederlande, Finnland) zusammen (s. Anhang A). Der Austausch fand vor allem bezüglich der Anwendungsfälle und im Rahmen der methodischen Arbeitspakete WP2 – WP4 statt.

¹ Chatti, Sami; Tolio, Tullio (Hg.) (2019): CIRP Encyclopedia of Production Engineering. Berlin, Heidelberg: Springer Berlin Heidelberg.

² Grieves, Michael; Vickers, John; (None) (2016): Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems. In Franz Josef Kahlen, Shannon Flumerfelt, Anabela Alves (Eds.): Transdisciplinary Perspectives on Complex Systems: Springer, pp. 85–113.

2 EINGEHENDE DARSTELLUNG

Die Grundidee des ASIMOV-Projektes war es, zu einem bestehenden oder zu entwickelnden System einen digitalen Zwilling (DT) zu erzeugen und diesen im virtuellen Raum für die zwei folgenden Aspekte zu nutzen:

- Der DT diene dazu eine künstliche Intelligenz (KI) im Umgang mit dem entsprechenden System zu trainieren.
- Die KI lernt, auf welche Art und Weise verschiedene Eingaben/Einstellungen am System das Verhalten des Systems beeinflussen.

Im Projekt fand speziell verstärkendes Lernen (im Englischen „Reinforcement Learning“, RL) als spezielle Form von KI Anwendung. Ein mit RL trainierter Agent (RLA) wurde anschließend dazu genutzt, den DT auf einen zu definierenden Anwendungsfall hin zu optimieren bzw. die optimalen Einstellungen für diesen Anwendungsfall zu finden. Nachdem der RLA eine entsprechende Konfiguration im virtuellen Raum gefunden hat, muss geprüft werden, wie die Ergebnisse auf das physische System zu übertragen sind. Hier können Abweichungen zwischen dem DT und dem physischen System entsprechende Anpassungen notwendig machen. Nach der Übertragung der Ergebnisse auf das physische System bedarf es einer Überwachung der Verhaltensweisen im physischen System, um Abweichungen vom erwarteten Verhalten schnellstmöglich identifizieren und beheben zu können.

Die folgende Abbildung veranschaulicht den vorgestellten Prozess.



Abbildung 1: Der ASIMOV-Ansatz – DT-basiertes Training von KI zur Optimierung von Systemkonfigurationen

Zur Umsetzung dieses Projektes nahm ein europäisches Konsortium bestehend aus (zeitweise) 17 Partnern aus zwei Ländern (Finnland, Niederlande und Deutschland) die Arbeit auf. Auch nach dem Ausscheiden Finnlands zum 05.07.2022 bildete das Konsortium mit zwei Großunternehmen, fünf kleinen und mittelständischen Unternehmen (KMUs) und zwei akademischen Partnern aus dem Bereich Modellierung und Simulation, Systems Engineering, sowie Data Science die gesamte Wertschöpfungskette des ASIMOV-Ansatzes domänenübergreifend ab. In diesem Konsortium stellte Deutschland mit sechs Partnern das zweitgrößte nationale Konsortium nach Finnland dar, jedoch hatte es mit ca. 4 Mio. € das kleinste Budget. Eine Darstellung des ursprünglichen, gesamten Konsortiums inklusive Finnland und des deutschen Anteils findet sich in Tabelle 1.

Europäisches Konsortium	Davon deutsches Konsortium
17 Partner	6 Partner
16,4 Mio. € Budget	4,0 Mio. € Budget
1321,2 Personenmonate	391 Personenmonate
3 Use Cases	1 Use Case (Unmanned Utility Vehicle)
4 Großunternehmen, 8 kleine und mittelständische Unternehmen, 5 akademische Partner	1 Großunternehmen, 4 kleine und mittelständische Unternehmen, 1 akademischer Partner

Tabelle 1: Gegenüberstellung der Gesamtkonsortiums und des deutschen Unterkonsortiums (urspr. Planung 04.2021)

In ASIMOV wurden Methoden und Technologien entlang der zwei Anwendungsfälle entwickelt: „Elektronenmikroskop“ (Niederlande, Leitung: TFS) und „Hochautomatisiertes Nutzfahrzeug“ (Deutschland, Leitung: AVL). Im Folgenden wird der Anwendungsfall des deutschen Konsortiums kurz vorgestellt.

UC2 „Unmanned Utility Vehicle (UUV)“

Der Anwendungsfall des Unmanned Utility Vehicle (UUV) konzentrierte sich auf ein Mobilitätssystem, das als Unterstützungssystem für kritische Produktions- und Lieferketten in einer kontrollierten Umgebung dient und eine sichere Mobilität und den Schutz von Risikogruppen gewährleistet. Die Entwicklung, Zertifizierung und der Betrieb eines solchen UUV erfordert eine Vielzahl von Kalibrierdaten, die sehr genau erhoben werden müssen, um eine optimale Konfiguration zu ermöglichen. Es müssen viele Komponenten konfiguriert werden, wie z.B. Steuereinheiten für Energiespeicherung, Antrieb, Umweltsensorik und Kommunikation. Zusätzlich müssen Prüfstände optimiert werden, in denen das Fahrzeug vor der Freigabe für die verschiedenen Anwendungsbereiche verifiziert und validiert wird. Im Rahmen dieses Anwendungsfalles sollte eine KI-basierte Systemoptimierung unter Verwendung eines DT aus Fahrzeug, Umgebung und Testlaborumgebung entwickelt, um die Kalibrier- und Testzeit deutlich zu verkürzen. Dies wurde prototypisch umgesetzt.




Abbildung 2 - : Demonstratorfahrzeug im Use Case UUV

2.1 Verwendung der Zuwendung und erzielte Ergebnisse

Im Folgenden werden die wesentlichen Tätigkeiten und erreichten Ergebnisse mit Beteiligung durch des jeweiligen Projektpartners getrennt nach Arbeitspaketen dargestellt.

2.1.1 OFFIS e.V. (OFFIS)³

Durch den Übergang des Bereichs Verkehr des OFFIS in das DLR Institut Systems Engineering für zukünftige Mobilität (DLR), sind nach sieben monatiger Arbeitszeit nur wenige Arbeiten final abgeschlossen und konkrete Ergebnisse erzielt worden. Zum 1.1.2022 wurden die jeweiligen Arbeitsstände einzelner Themenstränge an das DLR übergeben. Der Status der jeweiligen Arbeitsstände wird im Folgenden beschrieben. Die Arbeitsstände wurden anschließend durch das DLR fortgeführt. Die final erreichten Ergebnisse sind im Abschnitt des DLRs beschrieben. Im Folgenden ist der Stand der Arbeiten bis zum 31.12.2021 dokumentiert.

³ Zur Vollständigkeit wurde der OFFIS-Bericht durch DLR in den Zusammenhang des Gesamtabschlussberichts gesetzt und wiederaufgeführt.

2.1.1.1 WP1 – Industrial Use Cases

Ziel des WP1 war es, Anwendungsfälle in den nationalen Konsortien zu erarbeiten, um die in ASIMOV entwickelten Methoden und das gewonnene Wissen anzuwenden, und die aus der Anwendung resultierenden Erkenntnisse wieder in die inhaltlichen Arbeitspakete WP2 bis WP4 einfließen zu lassen.

OFFIS war hier maßgeblich bei der Ausgestaltung und Verfeinerung des Anwendungsfalls „Unmanned Utility Vehicle“ (UUV), bereitgestellt durch den Partner AVL, im deutschen Konsortium beteiligt. Hierzu hat OFFIS zur Strukturierung und Definition von Unteranwendungsfällen beigetragen sowie eine sog. Use Case Story entwickelt. Das Ziel des Unteranwendungsfalls 1 war die Optimierung der Szenarien, mit dem das UUV getestet werden kann, während der Unteranwendungsfall 2 sich mit der Optimierung der Sensorkalibrierung befasste.

In diesem Zusammenhang hat OFFIS die Organisation, das Erarbeiten von Inhalten, die Durchführung und die Dokumentation von vier Use Case Workshops übernommen bzw. entscheidend unterstützt. Inhalt und Ziel dieser Workshops war es, die gemeinsame Entwicklung des Anwendungsfalls UUV zu koordinieren, ein tiefgreifendes gemeinsames Verständnis zu entwickeln und eine thematische Unterteilung des Anwendungsfalls und Zuordnung der Projektpartner im deutschen Konsortium vorzunehmen. Hieraus folgte die Etablierung von vier Arbeitsgruppen zur weiteren, vertiefenden Entwicklung und Ausarbeitung zu den Themen:

- Umgebungssimulation
- Modellierung/Konzeptualisierung des RL-Agenten
- Feature Engineering
- Storage und Computing.

OFFIS hat in Zusammenarbeit mit den involvierten Partnern die Gemeinsamkeiten und Unterschiede der einzelnen Anwendungsfälle herausgearbeitet (siehe Deliverable D1.1.1 in Anhang B). Dieses Ergebnis ist als ein notwendiger Input an WP2 geliefert worden.

2.1.1.2 WP2 – Creating Twins

Ziel des WP2 war es, ausgehend von den verschiedenen Anwendungsfällen, Methoden und Konzepte zur effizienten Erstellung von DT zur KI-basierten Systemoptimierung zu entwickeln. Hierzu sollten die beteiligten Partner zunächst Methoden und Konzepte für die Anwendungsfälle im Rahmen der Proof of Concepts (vgl. Abschnitt 1.2) entwickeln und hieraus später generalisierte Ansätze ableiten. Die Unterziele sind in einzelne Unterarbeitspakete (Tasks T2.1 – T2.5) gegliedert.

OFFIS hat im Unterarbeitspaket T2.1, in den Methoden zur Identifikation relevanter Parameter entwickelt werden sollten, zur Anforderungserhebung und Revision eines Dokuments zur Parameteridentifikation in den Anwendungsfällen „UUV“ und „EM“ beigetragen. Die bis dahin erhobene Anforderungen wurden an das DLR übergeben. Die finalen Anforderungen sind im Deliverable D2.1.1 dokumentiert.

In T2.2 hat OFFIS zu den für das verstärkende Lernen (Reinforcement Learning, RL) essentiellen Konzepten in den beiden Anwendungsfällen beigetragen und diese konkretisiert. Dabei ging es primär um das Zusammenspiel mit dem jeweiligen DT. Hierzu wurde die Literatur auf anwendbare Konzepte gesichtet und begonnen diese identifizierten Konzepte auf den Use Case anzuwenden. Diese Konzepte wurden an das DLR übergeben und wurden final im Deliverable D2.2.1 dokumentiert.

Unterarbeitspaket T2.3 beschäftigte sich mit der Anwendung von Architekturmustern. Hier hat OFFIS zunächst Recherche zum Stand der Technik und bestehenden Architekturparadigmen betrieben und war maßgeblich an der Definition der für die Anwendungsfälle „UUV“ und „EM“ geeigneten Architekturmuster beteiligt. Die Recherchearbeiten und Muster lassen sich in Deliverable 2.3.1 finden.

In T2.4 hat OFFIS den wissenschaftlich-technischen Stand hinsichtlich dynamischer Verhaltensmodellierung analysiert, um hieraus später Methoden entwickeln zu können, die spezifisch für den Einsatz mit DTs sind. Ein Fokus lag dabei auf der Verhaltensmodellierung durch Menschenmodelle in Verkehrsszenarien und die Anpassung der Modellparameter für Modellinstanzierungen im Hinblick auf die Optimierung von Verkehrsszenarien im Anwendungsfall „UUV“. Die identifizierten Modelle sind in Deliverable 2.3.1 eingeflossen.

Unterarbeitspaket T2.5 behandelte die Validierung von DTs. In diesem Rahmen hatte OFFIS begonnen die in den bisherigen Konkretisierungsstufen der Anwendungsfälle „EM“ und „UUV“ möglichen konzeptionellen Validierungsmethoden anzuwenden. Weiter wurden für eine später anstehende Laufzeitvalidierung Anforderungen aufgestellt und mit den entsprechenden Use Case Providern kommuniziert. Diese Anforderungen, Validierungskonzepte und Ergebnisse sind final durch das DLR in Deliverable 2.5.1 dokumentiert worden.

2.1.1.3 WP3 – Training and Using AI

Ziel dieses Arbeitspakets war es, Methoden und Technologien zu entwickeln und zu evaluieren, um die Fähigkeiten der KI zur Optimierung und zum Finden optimaler Einstellungen für komplexe Systeme zu verbessern.

In WP3 konzentrierte sich OFFIS vor allem auf Aspekte der DT-gestützten KI-basierten Systemoptimierung/-konfiguration im Unterarbeitspaket T3.3, insbesondere auf die Generierung risikominierender Strategien (bezogen auf Sicherheit). Es wurde zunächst eine State-of-the-Art-Analyse zum Einsatz von verstärkendem Lernen (Reinforcement Learning, RL) für sicherheitskritische cyberphysische Systeme durchgeführt. Hierbei lag der Fokus auf Ansätzen zur effizienten und effektiven Identifikation seltener, kritischer Ereignisse und Risiken im Lernprozess (beispielsweise mittels sog. Importance Sampling). Weiter hat OFFIS Recherche zum wissenschaftlichen-technischen Stand hinsichtlich bestehender Architekturen und Interfaces für die RL-getriebene DT-Optimierung betrieben. Diese Arbeiten wurden vom DLR weitergeführt und wurden im Deliverable D3.3.1 dokumentiert.

Im Anwendungsfall „UUV“ hat OFFIS zudem erste Entwürfe erarbeitet, wie das typische Konzeptgerüst des verstärkenden Lernens zur Optimierung von Verkehrsszenarien angewendet werden kann. Hierzu gehören die Identifizierung der Zustände („states“), der Aktionen des Agenten („actions“) und der Belohnungsstruktur („rewards“) aus dem Use Case „UUV“, sodass die Konzepte jeweils Zustand der Verkehrsszenarien, Aktionen zur Anpassung und Kriterien zur Bewertung von Verkehrsszenarien (wie die Kritikalität) beschreiben. Das DLR hat diese Konzeptentwürfe im weiteren Verlauf des Projektes weiter ausgestaltet und hieraus allgemein anwendbare Methoden zur RL-getriebenen Systemoptimierung mittels DTs abgeleitet. Die Details und Ergebnisse sind in Deliverable D3.2.2/D3.3.2 eingeflossen.

2.1.1.4 WP4 – Application to Systems

Ziel des Arbeitspakets WP4 war es, Antworten auf die Frage der Übertragbarkeit der virtuellen Ergebnisse auf die physikalischen Systeme zu liefern.

OFFIS hat hierzu im Unterarbeitspaket T4.1 beigetragen, indem Unterschiede zwischen dem in diesem Arbeitspaket fokussierten Übertragen des Zustandes des DT auf das physikalische System und der initialen Validierung des DT herausgearbeitet wurden. Eine Auflistung der Unterschiede ist in Deliverable D4.1.1 eingeflossen. Des Weiteren hat OFFIS Kennzahlen (KPIs) mitdefiniert bzw. gemeinsam mit den Projektpartnern überarbeitet. Die KPIs wurden genutzt, um den Erfolg des ASIMOV-Ansatzes in den Anwendungsfällen „UUV“ und „EM“ aufzuzeigen. Anhand der KPIs wurden im weiteren Verlauf des Projekts Bewertungen durchzuführen. Die Ergebnisse wurden an WP5 übergeben und sind in Internal report 5.4.1 zu finden.

2.1.1.5 WP5 – Organizing for Success

OFFIS hatte die Leitung des WP2 sowie des Unterarbeitspakets T2.5 inne und koordinierte sowohl die Zusammenarbeit der fünf Unterarbeitspakete, als auch die Zusammenarbeit mit anderen Arbeitspaketen. Auf projektweiten Veranstaltungen wie dem internationalen Projekt-Kickoff (Juni 2021) und dem ersten General Assembly (Dez. 2021) hat OFFIS zudem das WP2 repräsentiert. Die genannten Leitungsfunktionen hat das DLR planmäßig im weiteren Verlauf des Projekts übernommen und fortgeführt.

Zur Verbreitung der mit dem ASIMOV-Projekt intendierten Ziele wurde weiterhin ein Beitrag zur öffentlich verbreiteten OFFIS-Hauszeitschrift „Datawork“ (Nr. 73) eingereicht.

2.1.2 AVL

Im Projekt ASIMOV hat AVL Deutschland GmbH die Rolle des Use Case Providers für das "Unmanned Utility Vehicle" (UUV) übernommen. Hierbei hat AVL diesen Use Case über die gesamte Projektlaufzeit hinweg vorangetrieben, untersucht und in entscheidenden Teilen exemplarisch ausgearbeitet. Hierbei wurde insbesondere ein Augenmerk auf die Anwendbarkeit der untersuchten Gebiete im industriellen Umfeld gelegt. Die Arbeitsleistung in den Arbeitspaketen WP1 bis WP5 werden nachfolgend beschrieben.

2.1.2.1 WP1

Das WP1 beschäftigte sich mit der Anwendung der untersuchten neuen Ansätze in den konkreten Anwendungsfällen der Use Case Provider. AVL hat hier wichtige Beiträge in Form von domänen-spezifischen Wissen zum Testen von und Testständen für automatisierte Fahrzeuge in T1.1 geliefert und die Leitung von T1.3 übernommen, welcher sich mit der Umsetzung der Use Case UUV beschäftigt.

In T1.1 wurden Gemeinsamkeiten und Unterschiede zwischen den beiden Use Cases des europäischen Gesamtprojekts identifiziert. Hierbei hat AVL Expertise im Bereich des UUV Use Case eingebracht und den Vergleich der beiden Use Cases entscheidend unterstützt. Die Ergebnisse (siehe Deliverable D1.1.1 und D1.1.2) in Form von Gemeinsamkeiten und Unterschiede zwischen den Anwendungsfällen konnten in WP2 bis WP4 genutzt werden, um möglichst vielseitig anwendbare Gesamtkonzepte zu entwickeln.

Als Use Case Provider hat AVL T1.3 geleitet. In dieser Rolle hat AVL die Koordination der Arbeiten am Use Case übernommen und gemeinsam mit den anderen Projektpartnern den Use Case detailliert beschrieben und ein Konzept für die Demonstration erarbeitet. Sämtliche Fortschritte im Zusammenhang dieser Demonstration sind entweder von AVL oder in Zusammenarbeit mit AVL entstanden. Hierzu zählt insbesondere der Aufbau der funktionsfähigen Toolkette, als auch die exemplarische Untersu-

chung von Einzelkomponenten, wie dem Feature Engineering, welches Simulationsergebnisse analysiert, bewertet und für die KI aufbereitet. Diese Arbeiten wurden detailliert in D1.3.1 bis D1.3.3 dokumentiert.

2.1.2.2 WP2

Das WP2 hatte den DT des Gesamtsystems zum Fokus. Wichtig ist, dass hierbei der Aspekt der Verwendung dieses DTs im Zusammenhang der Systemoptimierung mittels KI stets im Fokus steht. AVL hat sich hierbei in sämtlichen Arbeitspaketen eingebracht und wesentlich zu den entstandenen Ergebnissen beigetragen. Hierbei beschränkte sich die Mitarbeit nicht nur auf die Erforschung der Thematik im Hinblick auf den UUV Use Case, sondern auch auf die Konzeption generalisierbarer Konzepte.

T2.1 lieferte Ansätze zu einem einheitlichen Prozess zur Identifizierung relevanter Parameter für DTs, wobei die Herausforderung darin besteht, ein Gleichgewicht zwischen Genauigkeit und Ausführungszeit zu finden und gleichzeitig sicherzustellen, dass der DT wesentliche Qualitätsstandards erfüllt. Hier konnten keine finalen, konkreten Entscheidungsempfehlungen gegeben werden, jedoch erste wichtige Ansätze zur Beantwortung der Fragestellung entwickelt werden. Konkret wurde hier zunächst eine initiale Aufstellung der relevanten Parameter für den Use Case erstellt und eine Kategorisierung der Parameter vorgenommen (siehe Deliverable D2.1.1). Bei der anschließend im Arbeitspaket entwickelten Prozessbeschreibung für die Identifikation von passenden Modellen für DTs, sowie deren Parametrisierung, die federführend vom Projektpartner DLR geführt wurde, hat AVL ebenfalls durch kontinuierliches, konstruktives Feedback mitgestaltet und Expertise bzgl. Modellbildung für automatisierte Fahrzeuge und Testumgebungen eingebracht. Zusätzlich wurde auch das neue Konzept eines „Adaptation Models“ von AVL in den Task eingebracht, welcher es erlaubt, dynamisch anpassbare DTs zu erstellen, bei denen ein Sub Set der Parameter von Instanz zu Instanz angepasst werden kann. Dies erlaubt die kontinuierliche Sicherstellung eines realistischen Verhaltens des DT.

T2.2 hat die Bedeutung des DT in Beziehung zur KI-basierten Optimierung gesetzt. In dem Task wurden insbesondere die Schnittstellen des DT in Form von Datenvor- und Datennachbereitung näher betrachtet, sowie zusätzliche Möglichkeiten untersucht, wie eine virtuelle vielfältige Flotte an DTs den Trainingsprozess einer KI beschleunigen kann. Bei dieser konzeptuellen Untersuchung DTs hat AVL wesentliche Anforderungen an die Datennachverarbeitung und Konzepte geliefert, um insbesondere die Frage zu untersuchen „Wie genau muss ein DT sein, um seinen Zweck zu erfüllen?“. Diese Fragestellung wurde in dem Task in einer Form angegangen, in der sie anwendbar auf Fahrzeug-, Umgebungs- und Testsystemmodell ist. Hierbei wurde im Wesentlichen die Erkenntnis gewonnen, dass die Genauigkeit nur so hoch gewählt werden muss, sodass die nachverarbeiteten Daten ununterscheidbar zu den Originaldaten sind. Diese Genauigkeit hängt also wesentlich vom Anwendungsfall ab. Details dazu sind in D2.2.2 zu lesen. Zusätzlich wurde die Idee der Variationen und die Erstellung einer virtuellen Flotte aus DTs als wirkungsvolles Mittel für die Übertragbarkeit zwischen Optimierung des digitalen und realen Systems untersucht, welche maßgeblich von AVL eingebracht wurde. Die Konzepte an dieser Stelle sind aufbauend auf dem Adaptation Model, welches in T2.1 beleuchtet wurde.

Der strukturelle Aufbau und die Architektur eines DT wurde in T2.3 beleuchtet. Das hierfür untersuchte Konzept wurde zunächst gemeinschaftlich in einer das Gesamtkonsortium übergreifenden „Working Group“ zu Beginn des Gesamtvorhabens erarbeitet und anschließend in T2.3 weiter ausdefiniert. Hierbei ist sowohl die Architektur der Modelle innerhalb eines DT betrachtet worden als auch eine Verbindung zum physikalischen Zwilling, die für eine kontinuierliche Synchronisierung verwendet wird. Die erarbeitete Architektur wurde maßgeblich von AVL mitgestaltet, konnte jedoch Use Case übergreifend

verwendet werden. Bei der Architektur des DT wurde insbesondere auch auf Modularität geachtet, sodass Experten unterschiedlicher Domänen unabhängig voneinander an Teilen des DT arbeiten können. T2.4 wurde aufgrund der Umorganisation des Gesamtprojekts durch den Wegfall der finnischen Beteiligung als Teil von T2.3 bearbeitet. Hierbei wurde untersucht, wie die zugrundeliegende Struktur der Architektur das Verhalten des DT beeinflusst.

Die Validierung eines DT wurde in T2.5 untersucht. Neben der Untersuchung aktueller Validierungstechniken für diverse Subsysteme, bei denen AVL insbesondere den Einblick in automobile Systemmodelle geliefert hat, wurde auch der Unterschied zwischen der Validierung konventioneller Modelle und DTs untersucht und die Validierung in entsprechende Teilschritte unterteilt. Ein wesentlicher Teil traditioneller Validierungsmethoden konnte ebenfalls auf DTs angewendet werden, wobei ein entscheidender Unterscheid in der zusätzlichen Relevanz von Validierungsmethoden für den dynamischen Anteil des DT liegt. Diese müssen zur Laufzeit den Unterscheid zwischen realem und simuliertem System kontinuierlich Bewertung, wodurch sich zusätzlich Anforderungen hinsichtlich der Ausführungseffizienz ergeben. Diese Erkenntnisse wurde in Deliverable D2.5.1 detailliert dokumentiert. AVL hat hier maßgeblich bei der Zusammenstellung und Untersuchung der Techniken mitgewirkt.

2.1.2.3 WP3

Das WP3 beschäftigte sich mit der künstlichen Intelligenz für die Optimierung des Gesamtsystems. AVL hat in diesem Arbeitspaket in allen Tasks mitgewirkt und die Optimierung aus Sicht des Use Cases UUV untersucht und bewertet.

In T3.1 wurden Anforderungen an die Optimierungs-KI beschrieben, die aus den Use Cases hervorgehen. Hier hat AVL die Parameteroptimierung im UUV Use Case hinsichtlich einer KI-Optimierung analysiert und die Anforderungen ausdefiniert. Dieser Task wurde in weiteren Tasks als Grundlage verwendet, um KI-Funktionen zu untersuchen.

T3.2 hat die Architektur der KI untersucht. Hier konnte AVL die Konzepte hinsichtlich Variation, die bereits in T2.2 beschrieben wurden, sowie die Architektur aus der „Working Group“ bzw. T2.3 einbringen und damit Architekturspezifikationen für die KI gemeinsam mit den Forschungspartnern in Deliverable D3.2.2/3.3.2 definieren. Die Architektur setzt auf eine modulare Komposition des Gesamtsystems, die sich wesentlich an der klassischen Struktur von Reinforcement Learning Agenten orientiert, zusätzlich jedoch die parallele Ausführung von DT und realem System ermöglicht. Zusätzlich wurde die Synchronisierung beziehungsweise Überwachung zwischen diesen beiden Systemen vorgesehen. Zusätzlich wurden Elemente für die Orchestration des Gesamtsystems vorgesehen. Die entstandene Architektur wurde ferner aus verschiedenen Sichtweisen betrachtet, die sowohl Einblicke in die Implementierung, als auch Kommunikation geben. T3.3, der mit diesem Task fusioniert wurde, hat die Implementierung der KI aus technischer Sicht näher beleuchtet. Hier hat AVL die Implementierung im Gesamtsystem betreut und Schnittstellen zum DT zur Verfügung gestellt.

T3.4 hat die Validierung eines KI-Systems untersucht. Hier wurden diverse Ansätze untersucht und bewertet. Eine vollständige Validierung des Gesamtsystems stellt sich weiterhin als schwierig heraus. Es wurden jedoch Techniken aufgezeigt, mit denen bei der Erstellung des KI-Systems bereits in kleinen Schritten die Funktionsweise abgeprüft werden kann. Details sind D3.4 zu entnehmen.

2.1.2.4 WP4

AVL hat als Leitung des WP4 organisatorische Aufgaben rund um das Arbeitspaket übernommen. Das Arbeitspaket hat die Anwendung der Systematiken aus WP2 und WP3 auf das Gesamtsystem zum Hauptthema.

T4.1 wurde ebenfalls unter der Leitung von AVL durchgeführt. Hier wurde besonderes Augenmerk auf die Laufzeit des Systems gelegt und Konzepte dafür entwickelt, wie sowohl der DT als auch die KI fortwährend bewertet und synchronisiert werden können. Auch hier wurde das Konzept des „Adaptation Model“ hinsichtlich seiner Auswirkungen auf ein laufendes System betrachtet und verschiedenste Methoden für den Datenvergleich untersucht. Die Ansätze zur initialen Bedatung wurden bereits in WP2 untersucht, weshalb sich T4.1 mehr mit der Laufzeitverbesserung und Bedatungsupdates beschäftigt hat.

Der Task T4.2 hatte die Untersuchung der für die Anwendung von ASIMOV nötigen Tools und Applikationen zum Thema. Da AVL einen Teil, der für den UUV Use Case nötigen Simulationstools bereitgestellt hat, ergab sich daraus auch eine Betrachtung dieser Tools im ASIMOV Kontext. Hierbei wurde nicht nur eine Toolvorstellung durchgeführt, sondern auch eine Zuordnung auf die projektweite Lösungsarchitektur durchgeführt und Schnittstellen zu anderen Tools identifiziert. Bei der Anwendung in ASIMOV ergeben sich zusätzliche Anforderungen an bereits vorhandene Tools. Diese wurden ebenfalls betrachtet.

Task T4.3 hat sich mit der Gesamtarchitektur von ASIMOV beschäftigt und auch Teile des Tasks T4.4 übernommen, der aufgrund des finnischen Projektausstiegs als eigenständiges Arbeitspaket wegfiel. Dadurch wurde der Themenumfang um Standards erweitert. Die Umsetzung von ASIMOV wurde hier besonders aus der technischen Sicht betrachtet und die Softwarearchitektur untersucht. Hierbei wird besonders auf die Modularität eingegangen und betrachtet, welche Vorteile sich aus der gewählten Architektur und der spezifischen Umsetzung ergeben. Einflüsse insbesondere aus der Umsetzung des UUV Use Case sind hier eingearbeitet worden. Um ASIMOV zusätzlich einem breiten Anwendungsgebiet zu eröffnen, wurde zudem die Architektur exemplarisch auf weitere Use Cases im Bereich Eisenbahn, Offroad und Maritime angewendet und deren Umsetzbarkeit bewertet. AVL hat sich hier insbesondere durch die federführende Mitgestaltung der Gesamtarchitektur, der Umsetzung des Use Cases und der alternativen Anwendungsgebiete eingebracht.

2.1.2.5 WP5

Das Arbeitspaket WP5 hatte organisatorischen Charakter und beschäftigte sich mit der Veröffentlichung und Verwertung von ASIMOV Projektergebnissen. Wesentlich ist hier die Organisation der Projekttreffen „General Assembly“, sowie die konsolidierte Betrachtung von Veröffentlichungen und Verwertung der Projektergebnisse zu nennen. Um hier Beiträge zu leisten, hat AVL eine Projektwebsite (www.asimov-project.eu) erstellt. Diese kann als zentrale Anlaufstelle für Interessierte gesehen werden und fasst auch die veröffentlichten Arbeitsergebnisse zusammen. Diese wird voraussichtlich bis 2025 weiterbetrieben.

Neben diesen Aktivitäten wurden auch die KPIs des Projekts in diesem Arbeitspaket erarbeitet und über die Projektlaufzeit hinweg analysiert.

Gegen Ende des Projekts wurde ein zusätzliches Deliverable erstellt, das sogenannte „ASIMOV Cookbook“, welches als eine komprimierte Zusammenfassung der wichtigsten Projekterkenntnisse gesehen

werden kann, und dabei helfen soll, dass die ASIMOV Architektur einfacher in neuen Projekten eingesetzt werden kann. Zudem soll es als Entscheidungshilfe dienen, ob das eigene Problem durch den ASIMOV Ansatz gelöst werden kann.

2.1.3 DLR e.V.

2.1.3.1 WP1 – Industrial Use Cases

DLR trug zur Entwicklung des Anwendungsfalls „Industrial Use Cases“ hauptsächlich in zwei Bereichen bei:

KI-System

Im ersten Jahr des Projektes hat DLR zusammen mit den Partnern aus dem deutschen Konsortium ein gemeinsames Verständnis erarbeitet, welche Anforderungen das KI-System erfüllen muss. Eine Auflistung kann in den Deliverables D1.3.1 gefunden werden und diente als Basis von D3.1.2. Hierzu gehörte festzulegen welche Parameter optimiert werden können (action), auf welche Daten das System in welcher Form zugreifen muss (state) und wie diese durch das System evaluiert werden (reward). Speziell zum letzteren hat DLR die Kompetenzen zum Thema Szenarienkritikalität einbringen können. Zudem kamen weiche Anforderungen bzgl. Dateneffizienz und parallelisiertem Training. Die Anforderungen wurden systematisch im Deliverable D1.3.1 erfasst. Im Anschluss hat DLR über eine Literaturrecherche einen geeigneten Algorithmus identifiziert (Maximum a-Postiory Optimization⁴) und eine bestehende Implementierung angepasst (korrekte Formatierung der Ein- und Ausgaben) und erweitert (das Ausgeben von nun sowohl diskreten als auch kontinuierlichen Aktionen), um die Anforderungen zu erfüllen, und mit einer Testumgebung ausgestattet. Die Implementierung wurde über Docker in die Architektur des Anwendungsfalls eingebettet und den Partnern über einen Service von Norcom zu Verfügung gestellt.

Digitaler Zwilling

Um die Toolchain für die Optimierung des physischen Systems zu testen und zu demonstrieren, muss ein solches System sowie ein DT entwickelt werden. Hierfür hat DLR im Miniaturmaßstab ein Demonstrationssystem erstellt, welches den Anwendungsfall widerspiegelt und ermöglicht, einfach und Ressourcen-arm einen DT des Systems mit hinreichender Qualität zu erzeugen.

Hierfür wurde ein Vehicle-in-the-loop-System in Miniatur nachempfunden und dessen Perception als DT nachgestellt. Wie bereits erwähnt ist das Ziel der Anwendungsfall-Optimierung die Veränderung der virtuellen Umgebung bei gegebenen Eigenschaften eines Fahrzeugs und seiner Testumgebung. Dies ist in Abbildung 3 zu sehen, wo auf der rechten Seite die Schleife aus RLA, ein Szenario-Generator, ein Umgebungssimulator und das Feature Engineering zu sehen sind und auf der linken Seite das Fahrzeug in der Schleife mit der Simulationsumgebung zu sehen ist. Das System wurde als Demonstrator für ASIMOV auf dem ESI Symposium 2024 in Eindhoven (NL) vorgestellt. Die Entwicklung und „Lessons

⁴ Neunert, Michael; Abdolmaleki, Abbas; Wulfmeier, Markus; Lampe, Thomas; Springenberger, Tobias; Hafner, Roland et al. (2020): Continuous-Discrete Reinforcement Learning for Hybrid Control in Robotics. In Leslie Pack Kaelbling, Danica Kragic, Komei Suguira (Eds.): 3rd Conference on Robot Learning: PMLR (Proceedings of Machine Learning Research, 100), pp. 735–751.

learned“ des Demonstrators ist als open-access Konferenzbeitrag „Small Scale, Big Impact: Experiences from a Miniature ViL Testbed and Digital Twin Development“ veröffentlicht⁵.

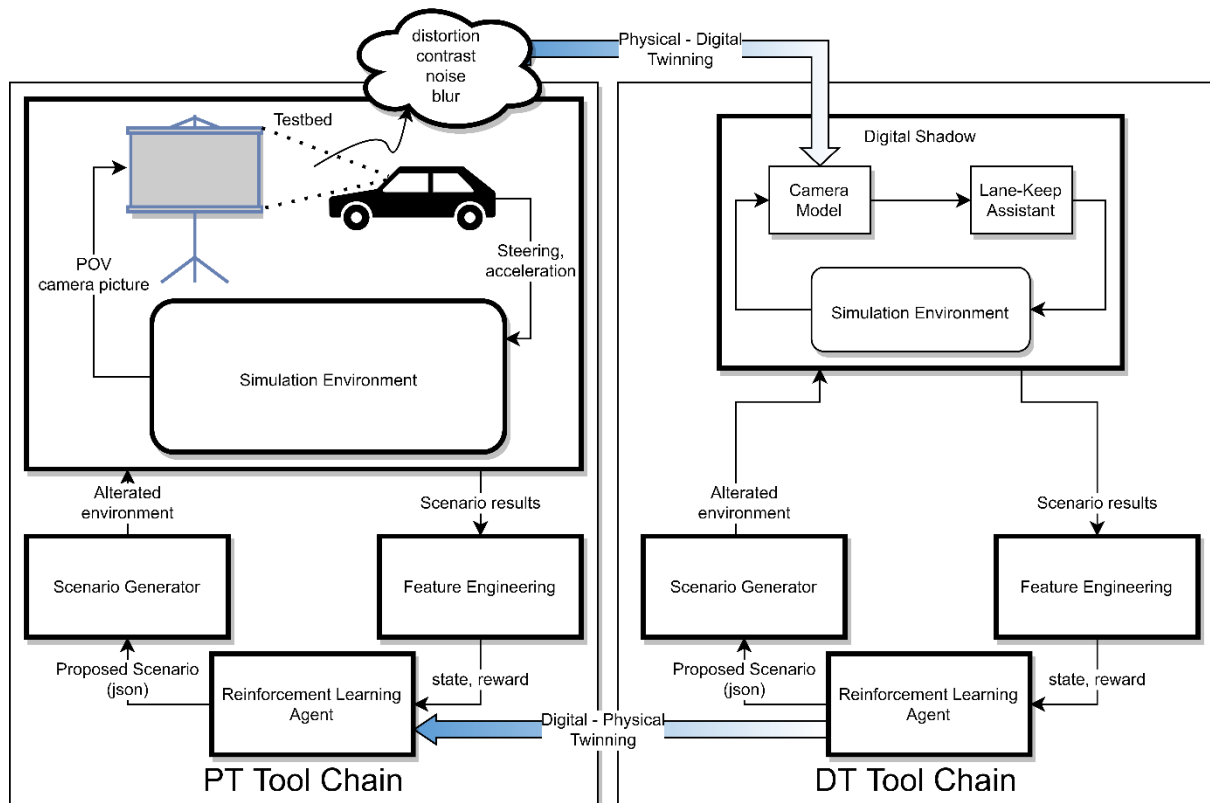


Abbildung 3 Überblick über die Interaktion zwischen der ASIMOV Tool Chain und dem physikalischen Demonstrationssystem. Diagramm publiziert in Modrakowski et al. (2024)⁴.

2.1.3.2 WP2 – Creating Twins

Das DLR setzte einen starken Fokus auf das WP2 bzgl. der Entwicklung und Validierung von DTs. Das DLR war hier nicht nur in der Rolle der Arbeitspaketleitung aktiv, sondern auch in allen fünf bzw. vier Tasks.

T2.1 hatte die Parameteridentifikation für DTs zum Thema. Hier hat DLR maßgeblich zur Erstellung eines Parameteridentifizierungsprozesses beigetragen. Dieser zeigte, in welchen Phasen der Entwicklung eines Modells relevante Parameter identifiziert werden und im Kontext des DT-basierten verstärkenden Lernens, was „relevant“ bedeutet und impliziert. Im weiteren Verlauf des Projekts wurde in Kooperation mit TrianGraphics eine Sensitivitätsanalyse der Eingangsparameter im UUV Anwendungsfall UUV durchgeführt und deren Eignung zur Identifizierung von Parameter evaluiert. Die Ergebnisse wurden im Deliverable D2.1.2 dokumentiert.

T2.2. untersuchte verschiedene Methoden, um den DT für die Verallgemeinerung des Optimierungsproblems zu konfigurieren. DLR entwickelte zusammen mit den Forschungspartnern einen Ansatz auf Basis des föderierten Lernens, um dies über den gesamten Lebenszyklus sicherzustellen. In diesem

⁵ Modrakowski, E., Rahenbrock, N., Möhlmann, E., Schlender, H. (2025). Small Scale, Big Impact: Experiences from a Miniature ViL Testbed and Digital Twin Development. In: Margaria, T., Steffen, B. (eds) Leveraging Applications of Formal Methods, Verification and Validation. Application Areas. ISO/FA 2024. Lecture Notes in Computer Science, vol 15223. Springer, Cham. https://doi.org/10.1007/978-3-031-75390-9_6

Zusammenhang konnte das DLR Expertise sowie akademische Publikationen zum Thema Modellvariation und föderierten Lernens in die Entwicklung des ASIMOV-Ansatzes einbringen. Dies wurden in D2.2.2 dokumentiert und öffentlich zugänglich gemacht.

DLR entwickelte in T2.3 zusammen mit den deutschen und niederländischen Forschungspartnern eine Referenzarchitektur für DTs, zugeschnitten auf deren Anwendung zur Datengenerierung für das Trainieren von Optimierungs-KIs. Dies beinhaltete eine Literaturrecherche zu möglichen Darstellungen, aber auch tiefgreifende Beiträge zum logischen Aufbau der Architektur. Die Forschung zu diesem Thema gipfelte in der durch das DLR getriebenen Publikation⁶ der Ergebnisse.

In T2.4 bzw. später T2.3 konnte das DLR Methodiken zur Identifikation und Modellierung von Verhaltensmodellen weiterentwickeln, welche in zwei Publikationen^{7 8} resultierten.

Die Validierung von DTs im Kontext von ASIMOV war ein zentrales Thema der Forschung des DLR im Projekt. Als Taskleiter von T2.5 leitete das DLR die Adaption von Validierungsmethoden an die veränderten Anforderungen der DTs im gegebenen Kontext. Speziell konnte DLR durch extensive Literaturrecherchen und Diskussionen mit den wirtschaftlichen Forschungspartnern akademische Methodiken und Sichtweisen einbringen, auf die Anwendungsfälle adaptieren und somit in die Anwendung überführen. Die Resultate wurden im Deliverable D2.5.1 veröffentlicht.

2.1.3.3 WP3 – Training and Using AI

Durch die zentrale Rolle in der Entwicklung des RLA im UUV Anwendungsfall konnte DLR nicht nur auf akademischer Ebene zu diesem Arbeitspaket beitragen. So konnten auf der einen Seite verallgemeinerte Anforderungen an den KI-Komponente entwickelt werden und Erfahrungen aus der Entwicklung des RL Agenten geteilt werden (siehe Deliverable D3.1.2). Des Weiteren konnte auch ein grundsätzliches Verständnis des Stands der Technik zum Thema RL (z.B. Transfer-Learning) durch Literaturrecherchen bei den Forschungspartnern vermittelt werden, was in Deliverable D3.2.1 dokumentiert ist.

Auch konnten Erfahrungen in der Architekturentwicklung aus WP2 übernommen und somit eine Architekturkonzept für die den RL-Agenten zusammen mit TNO entwickelt werden. Hier wurden die ersten Konzepte in Deliverable D3.2.2 dokumentiert.

2.1.3.4 WP4 – Application to Systems

Zusammen mit den Industriepartnern wurde in T4.1 eine Aktualisierungsprozess für den Abgleich von DT und PT entwickelt. Hier konnte DLR den akademischen Stand der Technik vermitteln und speziell auf unterschiedliche Methodiken zum Vergleichen von diversen Datenstrukturen verweisen. Ein gemeinsame Ergebnisdokumentation mit den Industriepartnern wurde über Deliverable D4.1.1 veröffentlicht.

⁶ Modrakowski, E. et al. (2024). Architecture for Digital Twin-Based Reinforcement Learning Optimization of Cyber-Physical Systems. In: Tekinerdoğan, B., Spalazzese, R., Sözer, H., Bonfanti, S., Weyns, D. (eds) Software Architecture. ECSA 2023 Tracks, Workshops, and Doctoral Symposium. ECSA 2023. Lecture Notes in Computer Science, vol 14590. Springer, Cham. https://doi.org/10.1007/978-3-031-66326-0_16

⁷ Rakow, A., Hajnorouzi, M., & Bairy, A. (2023). What to tell when?--Information Provision as a Game. arXiv preprint arXiv:2311.09776.

⁸ Hajnorouzi, M., Rakow, A., Bairy, A., Osterloh, J. P., & Fränzle, M. (2024, March). What Level of Power Should We Give an Automation? —Adjusting the Level of Automation in HCPS—. In European Dependable Computing Conference (pp. 14-21). Cham: Springer Nature Switzerland.

2.1.3.5 WP5 – Organizing for Success

DLR war fester Bestandteil der Organisation des Projektes. Zum einen übernahm es die Organisation des deutschen Konsortiums, leitete das WP2 und T2.5. Auch wurden Beiträge und Diskussionsgrundlagen zu den jährlichen „General Assemblies“ erstellt, online und offline Workshops zur Entwicklung des Anwendungsfalls UUV organisiert und Veröffentlichungen koordiniert.

2.1.4 LiangDao

2.1.4.1 WP1 – Industrial Use Cases

Ziel des WP1 war es, Anwendungsfälle in den nationalen Konsortien zu erarbeiten, um die in ASIMOV gewonnenen Methoden und Wissen anzuwenden, aber auch daraus resultierende Erkenntnisse wieder in die anderen inhaltlichen Arbeitspakete WP2 bis WP4 einfließen zu lassen.

LiangDao hat sich mit der Expertise der Firma im Bereich Sensorik und Umfelderfassung an der Evaluation der Anforderungen und Spezifikationen beteiligt (T1.1), sowie im Use Case „Unmanned Utility Vehicle“ (UUV) an den Diskussionen der Konzept- und Umsetzungsphase (T1.3). Allerdings stellte sich heraus, dass auf dem einplanten Prüfstand kein LiDAR simuliert werden kann, welches die zentrale Sensorplattform von LiangDao darstellt. LiangDao entwickelte daher ein eigenes Experiment in dem die LiDAR-Komponenten sowohl im physikalischen Zwilling (PT) als auch in einem DT getestet und verglichen, sowie letzterer validiert werden konnte. In das Experiment ließ LiangDao, so weit möglich, die Resultate und Erkenntnisse der UUV-Use-Case-Arbeiten einfließen (beschrieben in D1.3.3). Auch die verbliebenen Aufgaben der WP2-4 konnten anhand des Experiments bearbeitet werden (siehe Abschnitt 2.1.4.2-2.1.4.4). Schließlich kooperierte LiangDao für das Experiment mit RAC, um Kommunikationskonzepte zwischen PT und DT in einem konkreten Anwendungsfall zu entwickeln (Zuarbeit für RAC, siehe RAC).

Für das Experiment hat LiangDao LiDAR-Sensorkonzepte für ein autonomes Nutzfahrzeug, im konkreten Anwendungsfall ein autonomes Shuttle, sowie für eine stationäre Messtation erstellt. Auch wurden die benötigten Softwarekomponenten, entwickelt bzw. angepasst. Im Experiment fuhr das Shuttle, sowohl im PT als auch DT, auf einem vorprogrammierten Kurs und wurden durch die LiDAR-Messtation mit Objekterkennungsalgorithmus erfasst, siehe Abbildung 4. Die getrackten Pfade des PT und DT wurden anschließend verglichen, auch mit GNSS/RTK-Positionsdaten des Shuttles im PT, die als Ground Truth fungierten, und auf Abweichungen hin untersucht.




Abbildung 4 Experiment zum Vergleich der Performance von KI-basierten Objekterkennungsalgorithmen für LiDAR Sensoren in Physikalischen und Digitalen Zwillingen Links: Schema des Experiments im PT, rechts oben Foto der Durchführung im PT, rechts unten, LiDAR Abbild der PT- Umgebung mit erkanntem Shuttle (blaue Box). Das Experiment wurde im DT wiederholt und die Positionsmessungen mittels Objekterkennungsalgorithmus, PT und DT, wurden miteinander und mit der Ground Truth Messung via GNSS verglichen.

Mit dem Experiment wurde die grundsätzliche Einsatzmöglichkeit eines DT für Training und Validierung von LiDAR-Sensoren getestet, sowie für das gegebene Szenario, eine Einschätzung abgegeben, ob das verwendete, im Vergleich zur realen Umgebung, vereinfachte Weltmodell, ausreichend ist, um diese Aufgabe zu erfüllen. Die Fragestellung konnte positiv beantwortet werden.

2.1.4.2 WP2 – Creating Twins

WP2 beschäftigte sich mit der Entwicklung und Validierung von DTs, die für das Training von KI verwendet werden. In T2.1 wurden die für LiDAR-Objekterkennung relevanten Parameter für einen DT identifiziert und ausgearbeitet, wie diese in einem DT ressourcensparend umgesetzt werden können. Neben der Berücksichtigung von Sensorparametern (Zahl der eingesetzten Laser, Rotationsgeschwindigkeit des Sensorkopfes, Field-of-View, etc), stellte sich die Frage, wie realistisch die Umgebungssimulation und die Simulation der Sensorwahrnehmung sein muss, um eine Objekterkennung wie im PT zu gewährleisten. Hierzu wurde eine Literaturrecherche und eigene Tests durchgeführt, und basierend auf den Erkenntnissen ein geeignetes Programm (Carla) für die Simulationsumgebung des Use Cases ausgewählt. Die Ergebnisse des beschriebenen Experimentes wurden für eine weitere Analyse herangezogen. Zwar gibt es keine allgemeingültige Antwort auf den notwendigen Realitätsgrad einer Simulation, jedoch konnte bestimmt werden, wie hoch dieser für vorliegende Use Cases sein muss und wie dieser für andere bestimmt werden kann. Die gewonnenen Erfahrungswerte können zur weiteren Entwicklung von Produkten verwendet werden.

Im Rahmen von T2.2 hat LiangDao eine Datenbankstruktur für den Aufbau von Trainingsdatensätzen (real wie synthetisch, Speicherung, Verwaltung und Anwendung) zum Training von KI-basierten Objekterkennungsalgorithmen entwickelt. Der Objekterkennungsalgorithmus wurde mit einer definierten Eingangsschnittstelle entwickelt (T2.3), über die der Algorithmus sowohl LiDAR-Rohdaten des realen Sensors als auch aus der Simulationsumgebung erhalten kann. Letzteres wurde durch den Einsatz einer Carla-ROS-Bridge ermöglicht. Der Objekterkennungsalgorithmus separiert außerdem statische und dynamische Objekte. Die Ergebnisse können weiteren KI-basierten Agenten zur Verfügung gestellt werden, wie etwa in der Software-Pipeline des UUV-Use-Cases (T2.3).

Um die Übereinstimmungen und Abweichungen zwischen Objekterkennung basierend auf dem PT und DT bewerten zu können, wurde im Rahmen von T2.5 ein entsprechendes Konzept basierend auf Position und Orientierung der resultierend Bounding Boxes, sowie auf Precision und Recall der eigentlichen Objekterkennung erstellt.

2.1.4.3 WP3 – Training and Using AI

WP3 beschäftigte sich mit der Entwicklung von Techniken für KI-Training auf der Grundlage des DT. Dafür hat LiangDao zunächst im Rahmen von T3.1 eine State-of-the-Art Zusammenfassung der Datenerfassungsmethoden und -praktiken, sowie der Datenqualitätsmessung erstellt.

Basierend auf den Erkenntnissen der anderen Arbeitspakete wurde in T3.2 eine adäquate Referenzarchitektur eines Umfeld-DT zu KI-Schulung entwickelt, bestehend aus dem Programm Carla für die Simulationsumgebung, dem Objekterkennungsalgorithmus, einer Carla-ROS-Bridge zur Verbindung der beiden Komponenten, sowie der entwickelten Datenbankstruktur.

In T3.4 wurde basierend auf den Erfahrungen des beschriebenen Experiments ein Validierungskonzept für die Bewertung der Genauigkeit und Robustheit von KI-basierten Umfeld-Erfassung erstellt. Das Validierungskonzept nutzt die gleichen KPIs wie in T2.5, die zu erreichenden Zielwerte sind stark Use Case abhängig.

2.1.4.4 WP4 – Application to Systems

Das Arbeitspaket hatte die Anwendung der in WP2 und WP3 gewonnenen Erkenntnisse bzw. entwickelten Werkzeuge auf das Gesamtsystem zum Hauptthema. Die Beschreibung des Experiments erfolgte bereits in Sektion 2.1.4.1. Für die Umsetzung war es nötig einen hinreichenden DT der gegebenen realen Umgebung zu erstellen. Im Rahmen von T4.1 wurden dazu die realen Sensorsysteme der Messstation und des Shuttles eingesetzt, um ihre Umgebung abzuscannen und so eine Datengrundlage für die Modellierung zu erhalten.

In T4.2 erfolgte die Ausarbeitung von Metriken zur Bewertung der Leistungsfähigkeit von Sensorsystemen mit trainierten KI-basierten Objekterkennungsalgorithmen für den Einsatz in realen Systemen.

Schließlich wurde in T4.3 eine Bewertungsmatrix erstellt, mit der die Daten des DT des Umfeldes hinsichtlich der Datenschutzrichtlinien bewertet werden können. Eine Analyse zeigte, dass ein DT wie er für das Validieren oder Training von LiDAR basierten Objekterkennungsalgorithmen benötigt wird, ohne datenschutzrechtlich-bedenkliche Komponenten auskommt, da die Auflösung von LiDAR zu gering ist, um diese aufzulösen (KFZ-Kennzeichen, detaillierte Gesichter). Außerdem wird im ASIMOV-Ansatz für DT auf nicht benötigte Details verzichtet. Daher kann die gesamte Pipeline ohne datenschutzrechtlich-bedenkliche Daten betrieben werden.

2.1.4.5 WP5 – Organizing for Success

Das Arbeitspaket WP5 konzentrierte sich auf die Verwertung, Verbreitung und das Projektmanagement. Im Rahmen dieses Arbeitspakets nahm LiangDao an den regelmäßigen Treffen der WPs teil, sowie an mehreren General Assemblies (vor Ort), und Workshoptreffen mit den Themen KPIs, UUV Use Case (vor Ort und Online). Außerdem beteiligte sich LiangDao am zuvor beschriebenen „ASIMOV Cookbook“.

Für die Umsetzung des beschriebenen Experiments kooperierte LiangDao außerdem mit dem Lehrstuhl für Verkehrstechnik der TU München. Im Zuge dieser Zusammenarbeit entstand eine Masterarbeit mit dem Titel „Building a Digital Twin of a LiDAR-Based 3D-PointCloud for AI-Perception Training Purposes“. Es wird angestrebt die Zusammenarbeit mit dem Lehrstuhl fortzusetzen.

Schließlich aktualisierte LiangDao während des Projektes laufend seine Verwertungspläne der ASIMOV Erkenntnisse, siehe auch Sektion 2.4.

2.1.5 NorCom

2.1.5.1 WP1 - Industrial Use Cases

NorCom hat innerhalb von WP1 an T1.3 mitgewirkt. Sie hat die folgenden technischen Rahmenbedingungen hergestellt und in den Deliverables D1.3.1 bis D1.3.3 dokumentiert, sodass die verschiedenen Partnerkomponenten in einem einzigen Demonstrator vereint werden konnten.

Das entwickelte und den Projektpartnern bereitgestellte technische Grundgerüst basierte auf sogenannten Mock-Containern, die von den Projektpartnern später mit den tatsächlichen Komponenten ausgetauscht wurden.

Es wurde darauf geachtet, dass der anfängliche Prototyp möglichst auf jede technische Komplexität verzichtet, die nicht unbedingt nötig ist. Dadurch wurde erreicht, dass alle Projektpartner in der Lage waren die technische Lösung schnell zu durchdringen.

Die technische Komplexität wurde nach dem ersten technischen Durchstich bzw. der ersten Integration wieder erhöht, um sich einem realistischerem produktiven Use-Case zu nähern. Dies beinhaltete das Verwenden von Message Queing und einer Worker Architektur, welche für eine spätere Parallelisierung von Nutzen ist.

Für die effektive Zusammenarbeit wurden von NorCom eine Model Tracking/Management Plattform und eine Container Image Registry aufgesetzt, welche über die passwortgeschützten Adressen <https://asimov.norcom.de> und <https://asimovregistry.norcom.de> für die Projektpartner erreichbar sind.

2.1.5.2 WP3 – Training and Using AI

NorCom hat in WP3 Vorschläge und Erfahrungswerte zum Trainieren von RL Algorithmen eingebracht.

Im Rahmen von T3.1 konzeptionierte NorCom zusammen mit den Forschungspartnern Data Pre- und Postprocessing, Data Cleansing, und Data Management für KI-Modelle und KI-Training. Hier lag der Fokus dabei auf der Realisierbarkeit der Konzepte innerhalb der eigenen Data Management und Analytics Plattform. Die Konzepte wurden in Deliverable D3.1.2 dokumentiert.

Dabei hat sich NorCom in T3.3 und T3.4 an der Ausarbeitung der Referenzarchitektur (siehe Deliverable D3.3.2) beteiligt. NorCom hat Konzepte erarbeitet und getestet, wie Modelldiagnose und Modell-Management realisierbar ist und welche innerhalb der Daten- und Analyseplattform zur Anwendung kommen kann.

NorCom hat an einem Validationskonzept mitgearbeitet, um die Repräsentationsfähigkeit des DT für das physische System zu validieren. Die dazu zum Einsatz kommenden Methoden und Techniken wurden innerhalb der Daten- und Analyseplattform getestet.

2.1.5.3 WP4 – Application to Systems

NorCom hat in dem Arbeitspaket an Architekturthemen gearbeitet, die Digital Twinning mit KI im automotive Bereich und in genereller Form auf Ihrer Daten- und Analyseplattform ermöglichen. Dazu wurden Möglichkeiten erarbeitet, Metriken und andere Ergebnisse vom DT und dem physischen System so auf der Datenplattform abzulegen, dass Vergleiche und Validierungen über die dort integrierten KI-Apps möglich sind. Im Konkreten, wurden Konzepte zum Vergleich des DT mit dem physischen System im Rahmen von T4.1 entwickelt und in D4.1.1 verschriftlicht.

Im Rahmen von T4.2 wurden die Möglichkeiten für den Datenaustausch zwischen dem physischen System und der Datenplattform evaluiert (siehe Deliverable D4.2.1). Es wurde sichergestellt, dass verbreitete Datenübertragungsprotokolle von der Plattform unterstützt werden können und Datenzwischenverarbeitungsschritte modular bei der Anbindung hinzugefügt werden können.

Im Rahmen von T4.3 wurde das Konzept entwickelt und in D4.3.1 verschriftlicht, wie die Daten des DT und physischen System abgelegt werden können, sodass diese weiter analysiert und aufbereitet werden können. Auf der Daten- und Analyse-Plattform wurde dies auf Basis von sogenannten Facettierungen konzipiert und erprobt. Außerdem wurde das Konzept einer Workflow App entwickelt, um verschiedene Apps / Komponenten modular und unter Verwendung von Standards zu verbinden. Es wurde außerdem darauf geachtet, dass diese parallelisiert ausgeführt werden können und gegebenenfalls auch in Kubernetes Umgebungen gestartet werden könnten.

2.1.5.4 WP5 – Organizing for Success

Das Arbeitspaket WP5 konzentrierte sich auf die Verwertung, Verbreitung und das Projektmanagement. NorCom nahm an den General Assemblies und Workshoptreffen teil. Außerdem bearbeitete NorCom die vorgesehenen Dokumente zum Verwertungsplan und Verbreitung von ASIMOV bezogenen Inhalten. NorCom brachte die in ASIMOV gesammelten Erfahrungen in das bereits erwähnten, zusätzlichen Deliverable „ASIMOV Cookbook“ ein.

2.1.6 RAC

Im Fokus der Beiträge der RAC zu ASIMOV lagen vorrangig die Anbindung der DTs an reale Systeme. Dies konnte sowohl bei der Datenerhebung genutzt werden, um z.B. Systemkennwerte zu erfassen, die Einfluss auf die Modellierung nehmen, aber auch für das Training, bzw. die Simulation war es möglich reale Eingangsgrößen bereitstellen zu können. Die Validierung nutzt die Bidirektionalität der Kopplung, indem Aktionen aus dem DT im realen System verfügbar gemacht werden, wodurch eine direkte Validierung der KI-Gesamtfunktionalität durch Erhebung von KPI-Werten realisiert wird.

2.1.6.1 WP1 – Industrial Use Cases (T1.1, T1.3)

In diesem Arbeitspaket hat sich RAC an der Entwicklung des Gesamtkonzeptes des UUV-UseCases beteiligt, und daraus Anforderungen für die Anbindung der realen Systeme gewonnen. Insbesondere die erforderlichen Schnittstellen konnten spezifiziert werden. Im Rahmen der Konzeption konnten Kenntnisse aus der Standardisierung zu ASAM OpenSCENARIO, ASAM OpenDRIVE, aber auch zu ASAM MDF eingebracht werden.

Aufgrund der Verlagerung des UUV-UseCases hin zur simulativen Validierung konnte als Validierungs-UseCase zusammen mit LiangDao die Anbindung an ein reales autonomes Fahrzeug erarbeitet werden. Dabei waren vor allem die Kommunikationsschnittstellen vom und zum Fahrzeug von Bedeutung.

2.1.6.2 WP3 – Training and Using AI

In T3.1 und T3.2 konnte RAC Beiträge zu den potentiellen Schnittstellen realer Systeme, insbesondere automotive-spezifischen Schnittstellen liefern, die eine Anbindung an den DT, und dessen Trainingsprozess ermöglichen (siehe D3.1.2). Neben den technischen Anforderungen wurden auch Performance-Kriterien der Kommunikation als Anforderungen eingebracht, um z.B. bei der Simulation sicherzustellen, dass Messwerte oder Aktionen synchron und echtzeitnah übermittelt werden können. Die Anforderungen wurden schließlich in einer Referenzarchitektur umgesetzt, die in den unterschiedlichen Prozessen die Integration realer Systeme erlaubt.

In T3.4 wurden analog zu den Anbindungsmöglichkeiten innerhalb der Referenzarchitektur Möglichkeiten gefunden, wie eine entsprechende Validierung der KI-Funktionen erfolgen kann. Da für den UUV-UseCase dies ausschließlich simulativ umgesetzt werden sollte, wurde in Kooperation mit LiangDao ein Konzept für die Validierung einer KI-basierte Funktionalität mit Hilfe eines autonomen Fahrzeugs erstellt.

2.1.6.3 WP4 – Application to Systems

Die in WP3 erfassten Anforderungen, sowie die dort erstellte Referenzarchitektur wurde in den Tasks in WP4 teilweise umgesetzt.

Dazu wurde in T4.1 exemplarisch eine Flea-4 der Fa. CarMedialab GmbH als On-Board-System (OBS) ausgewählt welches als Kommunikationsinterface genutzt werden konnte. Ebenso wurde ermittelt, welche Komponenten auf dem System für die jeweilige Anbindung erforderlich sind, bzw. wie die Komponenten angepasst werden müssen, um einen bestimmten Use-Case zu unterstützen.

Zu Beginn wurden hierbei Komponenten berücksichtigt, welche die Anbindung eines realen Automotive-Systems ermöglichen, und somit Schnittstellen zu den Diagnose-, aber auch Messdaten eines Fahrzeugs bieten. Später wurden Schnittstellen hinzugefügt, um auch mit dem autonomen Fahrzeug von LiangDao, welches auf ROS basiert, Daten auszutauschen.

Das Teilarbeitspaket T4.2 wurde von RAC geleitet, und bis Q3/2023 regelmäßig Arbeitstreffen dazu durchgeführt. Als formales Ergebnis konnte schließlich planungsgemäß das Deliverable D4.2.1: Tools and Integration (s. Anhang B) bereitgestellt werden.

Im Rahmen von T4.2 konnten schließlich Teile der Konzepte prototypisch umgesetzt werden, um realitätsnahe Integrationstests durchführen zu können. Im Speziellen wurden dabei die folgenden Szenarien betrachtet:

- Ermittlung grundlegender Systemparameter für die Modellauslegung
- Validierung der Modellbildung und Konsistenz mit dem Realsystem.
- KPI-Messungen am physikalischen System; Erfassung von
 - i. Diagnose-/OBD-Daten
 - ii. Fahrzeug-spezifischen Messwerten
 - iii. Werte potenziell zusätzlicher verbauter Sensoren
- Komponente zur KI-basierten Vorverarbeitung von Daten, z.B. zur Klassifikation.
- Komponente zur Inferenzausführung eines trainierten KI-Modells bei

- i. der lokalen Datenaufzeichnung (offline)
 - ii. die direkte Datenauswertung (online), z.B. zur Trigger-Evaluation.
- Übertragung der ROS-Pose-Informationen zur Kalibrierung eines stationären LIDAR-Systems (mit LiangDao).

Um die erfassten Werte zu übertragen, wurden in T4.3 ebenfalls Komponenten erstellt, bzw. angepasst. Dabei wurden die unterschiedlichen Anwendungsfälle berücksichtigt, die z.T. eine lokale Anbindung (kabelgebunden oder WLAN) vorsehen, aber auch eine Remote-Übertragung (WLAN, 4G/5G) erfordern können. So wurde z.B. im Fall der LIDAR-Validierung mit LiangDao eine WLAN-Verbindung vorgesehen.

Bei der Übertragung wurde unterschieden zwischen der Offline-Übertragung (Übertragung lokal aufgezeichneter Daten, z.B. im MDF-Format), sowie einer Online-Übertragung (Übertragung von Messwerten direkt in die Simulation des DT, oder die Übertragung von Aktionen aus dem DT heraus).

Für die Erfassung der Messdaten konnten unterschiedliche Schnittstellen berücksichtigt werden, wie z.B. CAN, OBD oder auch XCP, aber auch ROS im Falle des autonomen Fahrzeugs.

Weitere Kriterien für die Datenübergabe waren Schnittstellen zur direkten Kopplung mit z.B. der Simulation per HTTP oder MQTT.

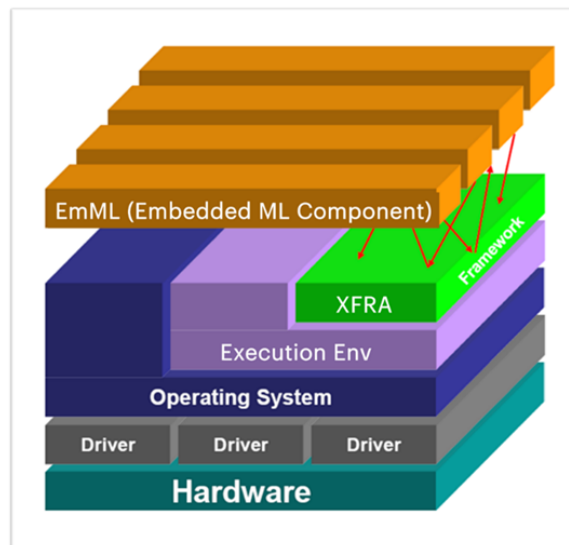


Abbildung 5: Integration von Embedded-Komponenten analog zu OSGi
[OSGi Alliance – OSGi Service Platform - Core Specification, Rel. 4, V4.3, 2011]

Um die funktionale Vielfalt der unterschiedlichen Komponenten handhaben zu können und alle möglichen Konfigurationen unterstützen zu können, wurde das eigene, OSGi-basierte, Framework XFRA so ergänzt, dass die Beispielkomponenten darüber verwaltet werden konnten (s. Abbildung 5).

Mit den Ergebnissen aus den vorangegangenen WPs und Teilaufgaben, wurde eine potenziellen Standardisierung im Kontext des ASAM e.V. in T4.4 geprüft. Dabei wurde jedoch erkannt, dass die ASIMOV-Referenz-Architektur und die entsprechende Umsetzung für eine Standardisierung noch nicht etabliert und damit ein Kandidat für eine Standardisierung ist.

2.1.6.4 WP5 – Organizing for Success

Im Fokus von WP5 stand das Projektmanagement, sowie die Verwertung und die Verbreitung der Ergebnisse.

RAC hat im Rahmen von T5.1 sowohl an den Workshop-Treffen der unterschiedlichen Arbeitspakete als auch an den General Assemblies vor Ort teilgenommen. Die entsprechenden Dokumente, wie z.B. der Verwertungsplan, wurden aktuell gehalten, sowie der Projektfortschritt auch auf der ITEA-Plattform dokumentiert.

Zur Unterstützung der Verbreitung der ASIMOV-Ergebnisse wurden in T5.3 sowohl Aktivitäten aus den aktuellen, noch laufenden ASAM-Standardisierungen in ASIMOV eingebracht, aber auch Erkenntnisse zu DTs bzgl. einer möglichen Standardisierung untersucht. Aufgrund der Neuartigkeit der Technologie sind es Kandidaten für eine zukünftige Standardisierungsbedarf.

2.1.7 TrianGraphics

Im Projekt ASIMOV lag der Schwerpunkt von TrianGraphics auf der automatisierten Generierung einer 3D-Umgebung für den Use Case "Unmanned Utility Vehicle (UUV)". TrianGraphics war an den Arbeitspaketen WP1, WP2, WP3 und WP5 beteiligt.

2.1.7.1 WP1 – Industrial Use Cases

Das Arbeitspaket WP1 umfasste die Entwicklung einer Proof-of-Concept-Anwendung, welche die Übertragung der im Rahmen des Projekts entwickelten Technologien auf industrielle Anwendungsfälle zum Ziel hat. Im Rahmen von Task 1.3 lag der Fokus auf dem UUV-Use-Case. Ein wesentlicher Bestandteil des Anwendungsfalls war die Scenario Generation Pipeline, welche die 3D-Umgebung generiert, in der die Simulation durchgeführt wird. Die Konzipierung und Entwicklung der Pipeline wurde im Rahmen des Projektes von TrianGraphics übernommen und in Deliverable D1.3.1 bis D1.3.3 dokumentiert.

Die Steuerung der Pipeline erfolgte durch einen RLA, der den Ablauf der Pipeline durch verschiedene Parameter beeinflussen kann. Unter anderem konnte die Platzierung von Objekten, wie zum Beispiel Autos, Bäumen und Laternen, der Detailgrad der platzierten Objekte sowie die Sichtbarkeit von Markierungen und Patches, wie etwa Gullideckeln oder Rissen in der Straße, beeinflusst werden.

Die Scenario Generation Pipeline stellt einen integralen Bestandteil der gesamten Prozesskette dar und wurde erfolgreich in die Gesamtarchitektur integriert, sodass eine Interaktion mit dem Gesamtsystem und die Durchführung der gewünschten Simulationen durchgeführt werden konnte.

2.1.7.2 WP2 – Creating Twins

WP2 beschäftigte sich mit der Entwicklung und Validierung von DTs, die für das Training von KI verwendet werden.

Im Rahmen von T2.1 wurden bezüglich des Use Case UUV Parameter abgeleitet und hinsichtlich ihrer Verwendung im DT analysiert. Dabei konnten vier Gruppen von Parametern identifiziert werden: Parameter zur Steuerung der Generierung der 3D-Umgebung, Parameter zur Steuerung der Simulation, Parameter zur Steuerung der Sensoren und Parameter zur Steuerung des Szenario Typs. Im Anhang zum Deliverable D2.1.1 findet sich eine detaillierte Liste der identifizierten Parameter.

Darüber hinaus wurde in T2.1 eine Untersuchung durchgeführt, deren Ziel die Analyse der Eignung von Umgebungsmodellen für den Einsatz im DT zur KI-basierten Optimierung war. Im Rahmen der Untersuchung wurde der Einfluss des Detailgrads von Modellen auf die Kritikalitätsmetrik analysiert. Im Zuge der Untersuchung wurden Modelle, darunter Laternen, Autos und Bäume, mit unterschiedlichem Detaillierungsgrad erstellt. Hierbei wurden verschiedene Parameter berücksichtigt, darunter die Polygonanzahl und -auflösung der Texturen. Zudem wurde die Scenario Generation Pipeline dahingehend modifiziert, dass der Detailgrad von Objekten für die Untersuchung über Parameter adaptiert werden konnte. Die Resultate der Untersuchung sowie weitere Details können dem Dokument D2.1.2 entnommen werden.

In T2.2 wurde die Eignung und die Einsatzmöglichkeiten standardisierter Datenformate zur Materialbeschreibung unter Berücksichtigung der Umfeldsensorik sowie der Verwendung realistischer Materialien erarbeitet. Ein besonderes Augenmerk wurde dabei auf die Ermittlung von Materialbeschreibungen gelegt, die ein realistisches Verhalten, beispielsweise bei ungünstigen Witterungs- und Beleuchtungsverhältnissen, aufweisen. Des Weiteren wurde die Leistungsfähigkeit der untersuchten Materialien analysiert, um eine effiziente Simulation zu gewährleisten. Die Resultate der Analyse sowie weitere Details können dem Dokument D2.2.2 entnommen werden.

Im Rahmen von T2.3 erfolgte eine Analyse der technischen Sicht der DT Architektur. Dabei wurden die Schnittstellen zwischen den DTs für die Co-Simulation untersucht. Des Weiteren wurden leistungsrelevante Themen erörtert und die Bedeutung von Informationssystemen, Standards und Datenformaten behandelt. Darüber hinaus wurden in Deliverable D2.3.2 Implementierungs- und Softwareaspekte ausführlich diskutiert.

Im Rahmen von T2.5 wurden Verfahren zur Verifizierung der Standardkonformität von DT untersucht. Ein besonderes Augenmerk wurde auf die Entwicklung von Automatismen zur Validierung der Umgebungsszenarien hinsichtlich Konsistenz und Vollständigkeit gelegt. Eine theoretische Beleuchtung der Validierungsverfahren kann dem Dokument D2.5.1 entnommen werden. Bezüglich der Szenario-Generation-Pipeline wurden vor allem Validierungsverfahren auf Dateiebene implementiert. Beispielsweise wurde ein Verfahren zur Prüfung der Anzahl der spezifizierten Objekte entwickelt.

2.1.7.3 WP3 – Training and Using AI

WP3 beschäftigt sich mit der Entwicklung von Techniken für KI-Training auf der Grundlage des DT.

Auf Basis der Resultate aus WP2 wurden die Anforderungen an den DT für das Training der KI erarbeitet. Im Rahmen der Untersuchungen wurde eine Analyse durchgeführt, um die Eignung des DT für die Extraktion von Daten zu evaluieren. Der Schwerpunkt der Untersuchungen lag auf der Generierung synthetischer Bilddaten. Die Extraktion der Bilddaten erfolgte unter Zuhilfenahme bildgebender Sensoren der Simulationsumgebung "Carla". Diese Sensoren stellten eine virtuelle Kopie eines Kamerasensors dar, der die 3D-Umgebung in Form von Bilddaten erfasst. Die Bilddaten wurden für das Training des RL-Agenten verwendet, wobei auch ihre Anwendbarkeit für den DT untersucht wurde. In D3.1.2 erfolgte eine detaillierte Erläuterung der Anforderungen der Daten, die für das Training der KI notwendig sind.

Im Rahmen des ASIMOV-Projekts wurde untersucht, ob Standardschnittstellen und Datenformate sich für die Erstellung von Umfeldmodellen eignen, welche wiederum für das KI-Training verwendet werden können. Zur Datenübertragung zwischen dem RL-Agenten und der Scenario Generation Pipeline wurde eine auf dem Standard JSON basierende Schnittstelle konzipiert und implementiert, welche die

Steuerung der Generierung der 3D-Umgebung ermöglicht. Für weiterführende Informationen bezüglich der Spezifikation der JSON-Schnittstelle sei auf das Dokument D1.3.3 verwiesen. Des Weiteren wurde eine Analyse zu effizienten Datenformaten für die Beschreibung von Umfeldmodellen durchgeführt. Im Rahmen dieser Analyse wurde das Dateiformat GLTF implementiert. GLTF bietet eine effiziente Speicherung der Daten und die Möglichkeit, unterschiedliche Materialbeschreibungen zu verwenden. Für weiterführende Informationen zu GLTF sei auf die Dokumente D2.2.2 und D3.2.2 verwiesen.

2.1.7.4 WP5 – Organizing for Success

Das Arbeitspaket WP5 konzentriert sich auf die Verwertung, Verbreitung und das Projektmanagement.

Im Rahmen dieses Arbeitspakets nahm Triangraphics an mehreren General Assemblies sowie an einem Konsortialtreffen teil. Die Zusammenkunft diente dem Austausch mit den Projektpartnern, sowie der Präsentation von Fortschritten beim Projekt. Zudem wurden die nächsten Schritte zur Förderung des Projekts abgestimmt. Im Rahmen der Treffen wurden beispielsweise die Fortschritte der Szenario-Generierung-Pipeline und von T2.1 präsentiert.

Des Weiteren nahm Triangraphics aktiv an Workshops teil und unterstützte die Entwicklung von Key Performance Indicators (KPIs) für die verschiedenen Tasks des Projekts. Außerdem übernahm Triangraphics das Tracking der Fortschritte von T2.1, um den Erfolg und die Zielerreichung im Projekt sicherzustellen.

2.2 Zahlenmäßiger Nachweis

Im Rahmen der Projektarbeit entstanden folgende Kosten durch die Projektpartner:

- Die zahlenmäßig größte Position waren die Personalkosten der Mitarbeitenden der Projektpartner.
- Durch die halbjährigen Projekttreffen und zusätzliche Workshops sind Reisekosten als zweiter signifikanter Kostenblock angefallen. Durch die Covid-19 Pandemie wurden solche Treffen im frühen Stadium des Projektes virtuell bzw. hybrid durchgeführt, was zu einer Reduzierung der Kosten geführt hat.
- Zu den obigen Positionen kamen Reisen zu Wissenschafts- und Industriekonferenzen inklusive deren Teilnehmergebühren, um die Projektergebnisse zur wirtschaftlichen Nutzung zu veröffentlichen.
- Eine vierte Position waren Materialkosten, die zum Bau der Demonstratoren (z.B., von DLR und LiangDao) angefallen sind.

Für detaillierte zahlenmäßige Nachweise wurden Kostenaufstellungen gesondert durch die Partner zur Verfügung gestellt.

2.3 Notwendigkeit der Zuwendung

Die Entwicklung, Erprobung und Optimierung von sicherheitskritischen Systemen auf Basis von KI (insbesondere hochautomatisierte Nutzfahrzeuge) befindet sich auch nach dem Projekt noch in einem frühen Stadium. Obwohl KI bereits viele Probleme lösen kann, sind diese vor allem im Bereich der nicht-sicherheitskritischen Anwendungen zu finden, wo eine Fehlfunktion keine direkten Auswirkungen auf Menschenleben oder die Umwelt oder tiefgreifende finanzielle Auswirkungen hat.

Die Erprobung von hochautomatisierten sicherheitskritischen Systemen ist jedoch für die deutsche KI-Wirtschaft und die Automobilindustrie von entscheidender Bedeutung, um den Markt der hochautomatisierten Fahrzeuge zu bedienen. Um dies zu erreichen, mussten jedoch die Entwicklung und die

Anwendung von Methoden zur Erprobung, Validierung und Absicherung solcher Systeme vorangebracht werden. ASIMOV konnte in zentralen Punkten hier erste wegweisende Ansätze beisteuern und diese über das deutsche Konsortium in einer ersten prototypischen Anwendung über Produkte und Dienstleistungen der Industriepartner in die zukünftige wirtschaftliche Anwendung bringen.

Ohne eine entsprechende Förderung hätten Risiken in der Forschung der grundlegenden Bausteine des DT-basierten RL-Training zur Optimierung von hochautonomisierten sicherheitskritischen Systemen nicht abgedeckt werden können. Die Förderung dieses Projektes hat einen Beitrag dazu geleistet, dass Deutschland die Wettbewerbsfähigkeit im Bereich der hochautomatisierten Fahrzeuge behält. Unser Ziel es die Sicherheit und Zuverlässigkeit von automatisierten Fahrzeugen erhöhen, was für den Schutz von Menschenleben und der Umwelt von entscheidender Bedeutung ist.

2.4 Voraussichtlicher Nutzen, insbesondere Verwertbarkeit der Ergebnisse

AVL beabsichtigt, die durch das Vorhaben gewonnenen Erfahrungen im Bereich künstliche Intelligenz und DTs in verschiedenen Tools einzubringen, um das Testen autonomer Fahrzeuge zu vereinfachen. Dazu zählen insbesondere die flexible Struktur zur modularen Anbindung verschiedenster Simulationstools in deren jeweiliger Domäne und der automatisierte Workflow, von der Szenarien Variation bis hin zur automatisierten Auswertung. Beide Techniken wurden im Rahmen exemplarischer Demonstratoren in ASIMOV erforscht und zeigten vielversprechende Ergebnisse.

DLR ist ein anwendungsorientiertes Forschungszentrum. Es beabsichtigt seine errungene Expertise und seine Forschungsergebnisse im Allgemeinen und hier im Speziellen aus dem ASIMOV-Projekt in die industrielle Anwendung zu bringen und damit die Stärkung der Wettbewerbsfähigkeit der deutschen Industrie zu unterstützen. Hierzu wird das am Projekt beteiligte DLR Institut Systems Engineering für zukünftige Mobilität seine Ergebnisse aus dem Projekt in eigene Lösungen integrieren. Hierüber soll es gelingen wirtschaftliche Verwerter für diese Ergebnisse zu gewinnen.

LiangDao hat im Zuge von ASIMOV seine konventionellen Umfeld-Erfassungssysteme um KI-basierte Objekterkennungsalgorithmen erweitert, die bereits zum Projektabschluss über eine signifikant bessere Performance verfügen (Geschwindigkeit und Qualität der Ergebnisse) als die zuvor verwendeten Systeme. Die neuen Komponenten lassen sich aufgrund der KI-Grundlage außerdem schneller weiterentwickeln bzw. an neue Use Cases anpassen. Für die Generierung der benötigten Trainingsdaten kann nun auch auf DTs zurückgegriffen werden, was die Entwicklung der Systeme weiter beschleunigt. LiangDao plant eine Erweiterung des Produktportfolios auf Ground Truth Messungen im Automotive Bereich, Smart City Lösungen mit stationären Stationen und autonome Shuttles für Forschung und Entwicklung.

NorCom hat durch die Mitarbeit an ASIMOV Lösungskompetenz und Erfahrung bezüglich Digital Twinning gewonnen und kann sein Consultingangebot erweitern. NorCom plant die in ASIMOV erarbeiteten Konzepte innerhalb der Daten- und Analyse Plattform DaSense seinen Kunden zur Verfügung zu stellen. Zum Beispiel wird NorCom die Konzepte zu ML-Model Training, Tracking und Serving auf der Daten- und Analyseplattform DaSense zur Anwendung zu bringen und damit Kunden aus der Automobilindustrie aber auch aus anderen Bereichen einen Mehrwert bieten. Ein weiteres Beispiel ist die Realisierung von skalierbaren Workflow-Anwendungen nach dem Beispiel des UUV Use-cases, was sich auch in andere Anwendungsbereiche übertragen lässt.

RAC konnte durch die Ergebnisse aus ASIMOV grundlegende Kenntnisse zur Integration von DTs in den Trainingsprozess von KI-Systemen gewinnen. Entsprechend der daraus resultierenden Anforderungen konnten Grundlagen geschaffen werden, die eigene Embedded Entwicklung auch auf solche Systeme,

insbesondere zur Kopplung von DTs mit realen Systemen, auszurichten. Damit wird es möglich entsprechende Daten aus den realen Systemen zum einen für das Training von KI-Systemen bereitzustellen, aber auch die Aktionen von DTs im Realsystem zu ermöglichen, und so die KI-Funktion zu validieren. Die entsprechenden Schnittstellen und Komponenten können nach Projektende zu entsprechenden Produkterweiterungen weiterentwickelt werden. In der Standardisierung sind in diesem Bereich aktuell nur Segmente standardisiert. Im Projekt konnten hier Kandidaten für Standardisierungsinitiativen identifiziert werden, die zu einer erhöhten Abdeckung bei der Standardisierung führen könnten.

Triangraphics prognostiziert Zuwächse durch die Integration der Forschungsergebnisse in die Produktpalette sowie durch Wachstum im Dienstleistungssektor. Vorteile ergeben sich aus der automatischen Generierung von variierten 3D-Umgebungen, die als Trainingsdaten für künstliche Intelligenz verwendet werden können. Der Nutzen erstreckt sich auf diverse Industriezweige, insbesondere auf die Automobil-, Verteidigungs- und Luftfahrtindustrie.

2.5 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Während der Projektlaufzeit sind keine umfassenden Ergebnisse Dritter auf dem Gebiet des Vorhabens bzgl. DT-basiertes KI-Training bekannt geworden. Bzgl. des Anwendungsfalls UUV ist eine Veröffentlichung⁹ bekannt geworden, die RL zur Optimierung von Szenarien verwendet. Diese beinhaltet jedoch nicht die Anwendung von DTs und deren Fähigkeiten und ist somit nur bedingt relevant und überlappend mit der Forschung in ASIMOV.

Insbesondere wurden auch keine komplementären Bestrebungen hinsichtlich einer möglichen Standardisierung in diesem Bereich bei der ASAM festgestellt. Aktuell erarbeitet ASAM mit OpenODD (Operational Design Domain) einen Standard, der insbesondere für die Zulassung relevant sein wird. Mit ASAM CMP (Capture Mode Protocol) wurde ein Standard entwickelt, der die Erfassung der Daten unterschiedlicher Sensoren (digital, analog) synchronisieren soll. Und mit einer Standardisierungsinitiative zur Beschreibung der Straßen- und Bodenbeschaffenheit kann zukünftig die Ground-Truth verbessert werden.

2.6 Veröffentlichungen

Die folgende Tabelle enthält die Publikationen der deutschen Partner, die veröffentlicht wurden oder bis zum 28.02.2025 geplant sind:

Typ	Titel	Autoren	Veranstaltung	Jahr	Link
Zeitschriftenartikel	Die digitale Schulbank für Künstliche Intelligenz	Modrakowski, Elias; Henning, Tabea	Dataworks Nr. 73	2021	https://www.offis.de/offis/aktuelles/meldung/datawork-nr-72-erschienen-1.html
Vortrag	How model based V&V improves safety assurance in the development of	Schyr, C.	ESI International Digital Enablement Week	2021	

⁹ Koren, M., Alsaif, S., Lee, R., & Kochenderfer, M. J. (2018, June). Adaptive stress testing for autonomous vehicles. In *2018 IEEE Intelligent Vehicles Symposium (IV)* (pp. 1-7). IEEE.

Typ	Titel	Autoren	Veranstaltung	Jahr	Link
	highly auto- mated vehicles				
Internetauftritt	Asimov Website	----	----	2022	www.ASIMOV-project.eu
Konferenz	AI-based Opti- mization of Dig- ital Twins of Un- manned Com- mercial Vehicles	Schyr, C.; Braun, N.; Oberpeilstei- ner, S.	7th International Commercial Vehi- cle Technology Symposium (Kai- serslautern)	2022	
Konferenz	Efficient Use of Multibody Sim- ulation on the Vehicle-in-the- Loop Test Bench	Schyr, C.; Braun, N.; Hartwecker, A.; Müller, S.; Oberpeilstei- ner, S.	AVEC (Kanagawa)	2022	
Vortrag	Using AI to im- prove Scenario- Based Testing	N. Braun	ESI Symposium (Veldhoven)	2022	
Konferenz	Effizienter Ein- satz von MKS am Vehicle-in- the-Loop Prüf- stand	Oberpeilstei- ner, S.; Hart- wecker, A.; Müller, S.; Braun, N.; Schyr, C.	AVL German Sim- ulation Confer- ence (Regens- burg)	2022	
Konferenz	Ergebnis der Analysen der ASAM Study Group zu etab- lierten und neu- eren Testverfahren im Lebenszyklus von hochautomati- sierten und au- tonomen Fahrfunktionen	Armin Rupalla, ASAM e.V.	Diagnose Tagung Dresden 2022	2022	https://diag- nose-ta- gung.de/rueck blick/15-ta- gung-diag- nose-in-me- chatronischen- fahrzeugsyste- men-22
Konferenz	Architecture for Digital Twin- Based Rein- forcement Learning Opti- mization of Cyber-Physical Systems	Elias Mo- drakowski, Ni- klas Braun, Mehrnoush Hajnorouzi, Andreas Eich, Narges Ja- vaheri, Richard Doornbos, Se- bastian Moritz, Jan-Willem Bikker & Rut- ger van Beek	ECSA 2023	2023	doi.org/10.100 7/978-3-031- 66326-0_16

Typ	Titel	Autoren	Veranstaltung	Jahr	Link
Konferenz	Digital Twin - Generation and Variation in Reinforcement Learning	Stephan Kussmaul	DSC 2023 Europe (Driving Simulation Conference)	2023	
Konferenz	Digital Twin - Generation and Variation in Reinforcement Learning	Stephan Kussmaul	Graz Symposium Virtual Vehicle 2023	2023	
Konferenz	Validation of ASAM OpenX & Variation of 3D Scene Maps	Mirco Nierenz	Autonomous Vehicles Europe 2023	2023	
Konferenz	What to tell when? – Information Provision as a Game	Rakow, A., Hajnorouzi, M., & Bairy, A.	FMAS 2023	2023	https://arxiv.org/abs/2311.09776
Konferenz	Small Scale, Big Impact: Experiences from a Miniature ViL Testbed and Digital Twin Development	Elias Modrakowski, Niklas Rahenbrock, Eike Möhlmann, Henning Schlender	ISoLA 2024	2024	doi.org/10.1007/978-3-031-75390-9_6
Konferenz	Providing Evidence for the Validity of the Virtual Verification of Automated Driving Systems	B. Neurohr, T. de Graaff, A. Eggers, T. Bienenmüller, E. Möhlmann	European Dependable Computing Conference, 2024	2024	doi.org/10.1007/978-3-031-56776-6_1
Konferenz	What level of power should we give an automation? --Adjusting level of automation in HCPS	Mehrnoush Hajnorouzi, Astrid Rakow, Akhila Bairy, Jan-Patrick Osterloh & Martin Fränzle	EDCC 2024 Workshops. EDCC 2024	2024	doi.org/10.1007/978-3-031-56776-6_2
Demonstration	How do you validate the Digital Twin in Digital Twin-based Reinforcement learning?	Elias Modrakowski	ESI Symposium 2024	2024	https://elib.dlr.de/204081/
Konferenz	Von der Telemetrie zur Telesoperation	Armin Rupalla, Thomas Kotschenreuther, Dr. Frank Hantschel	Diagnose Tagung Dresden 2024	2024	https://diagnose-tagung.de/rueckblick/17-tagung-diag-

Typ	Titel	Autoren	Veranstaltung	Jahr	Link
					nose-in-mechatronischen-fahrzeugsystemen-2024

Anhang A. Liste aller ASIMOV Partner

Im Folgenden werden die an ASIMOV partizipierenden Partner aufgelistet inklusive des Zeitraums deren Beteiligung im Projekt.

Partner	Kürzel	Land	Zeitraum der Beteiligung
AVL Deutschland GmbH	AVL	DE	01.06.2021 – 31.05.2024
CQM	CQM	NL	01.06.2021 – 31.05.2024
DLR e.V.	DLR	DE	01.01.2022 – 31.05.2024
Eindhoven University of Technology	TU/E	NL	01.06.2021 – 31.05.2024
Helmee Imaging OY	HELMEE	FI	01.06.2021 – 05.07.2022
LiangDao GmbH	LIANGDAO	DE	01.06.2021 – 31.05.2024
NorCom Information Technology GmbH & Co.KGaA	NORCOM	DE	01.06.2021 – 31.05.2024
OFFIS e.V.	OFFIS	DE	01.06.2021 – 31.12.2021
RA Consulting GmbH	RAC	DE	01.06.2021 – 31.05.2024
Sensmet Oy	SENSMET	FI	01.06.2021 – 05.07.2022
Symbio Finland Oy	SYMBIO	FI	01.06.2021 – 05.07.2022
Thermo Fisher Scientific	TFS	NL	01.06.2021 – 31.05.2024
Tieto Finland Oy	TIETO	FI	01.06.2021 – 05.07.2022
TNO	TNO	NL	01.06.2021 – 31.05.2024
TrianGraphics GmbH	TG	DE	01.06.2021 – 31.05.2024
University Oulu	OULU	FI	01.06.2021 – 05.07.2022
Valmet Automation	VALMET	FI	01.06.2021 – 05.07.2022
VTT Technical Research Centre of Finland Ltd.	VTT	FI	01.06.2021 – 05.07.2022

Anhang B. Liste aller Projektergebnisse (Deliverables)

Die folgende Tabelle listet alle Deliverables, die bislang im Rahmen von ASIMOV erstellt worden sind, auf. Dabei sind Deliverables, welche durch einen deutschen Partner geleitet wurden, in Grün eingefärbt und Deliverables, welche unter Beteiligung deutscher Partner entstanden, in Orange eingefärbt. Insgesamt war das deutsche Konsortium an 2 von 4 Deliverables (50%) beteiligt. Bei Deliverables ohne deutsche Beteiligung handelt es sich um jene zum Projektmanagement (2) und Anwendungsfälle, in denen kein deutscher Partner aktiv war (0).

Del. Nr.	Del. Name	WP Nr.	Leitung	Dissem. vel ¹⁰	Le-	Fertigstellung
IR1.1.1	Specifications and Commonality Analysis	1	TFS	CO		26.11.2021
IR1.1.2	Specifications and Commonality Analysis	1	TFS	CO		
IR1.2.1	Proof of Concept Demonstration and Evaluation electron microscopy	1	TFS	CO		26.11.2022
D1.2.2	Proof of Concept Demonstration and Evaluation electron microscopy	1	TFS	PU		20.03.2023
D1.2.3 / IR1.2.3	Proof of Concept Demonstration and Evaluation electron microscopy	1	TFS	CO		07.05.2024
D1.3.1 / IR1.3.1	Proof of Concept – Use case Unmanned Utility Vehicle	1	AVL	PU/CO		25.11.2022
D1.3.2 / IR1.3.2	Proof of Concept – Use case Unmanned Utility Vehicle	1	AVL	PU/CO		12.04.2023
D1.3.3 / IR1.3.3	Proof of Concept – Use case Unmanned Utility Vehicle	1	AVL	PU/CO		30.04.2023
D2.1.1	Identification of relevant parameters modelled in DT	2	TG	CO		12.9.2022
D2.1.2	Identification of relevant parameters modelled in DT	2	TG	PU		01.05.2024
D2.2.1	Methods and Tools for Training AI with Digital Twin	2	Tue	PU		30.11.2022
D2.2.2	Methods and Tools for Training AI with Digital Twin	2	Tue	PU		31.05.2024
D2.3.1	Architecture of optimized digital twins for AI-based training	2	TNO	PU		28.06.2023
D2.3.2	Architecture of optimized digital twins for AI-based training	2	TNO	PU		08.05.2024
D2.5.1	Digital Twin Validation - Methods and Techniques	2	DLR	PU		31.01.2024
D3.1.1	Requirements for AI-technology for DT-based AI-training and for system optimisation/configuration	3	TNO	CO		07.01.2022

¹⁰ PU = Public, CO = Confidential

Del. Nr.	Del. Name	WP Nr.	Leitung	Dissem. vel ¹⁰	Le-	Fertigstellung
D3.1.2	Requirements for AI-technology for DT-based AI-training and for system optimisation/configuration	3	Norcom	PU		21.11.2023
D3.2.1	Architecture and technical approach for DT-based AI-training: state of the art	3	TNO	PU		30.03.2022
D3.3.1	Architecture and technical approach for DT supported AI-based system optimization/configuration	3	TFS	PU		20.03.2022
D3.2.2 /D3.3.2	Architecture and technical approach for DT supported AI-based system optimization/configuration	3	Tue	PU		11.04.2024
D3.4.1	AI Algorithm Validation and Diagnosis	3	CQM	CO		22.05.2024
D4.a	ASIMOV Reference Architecture	4	TNO	PU		25.05.2022
D4.1.1	Application to Systems - Methods and Techniques	4	AVL	PU		01.12.2022
D4.2.1	Tools and Integration	4	RAC	PU		30.11.2023
D4.3.1	Architecture and Transfer	4	Norcom	PU		16.05.2024
IR5.1.1	IR5.0 v1 ASIMOV Project Handbook	5	TNO	CO		26.08.2021
IR5.1.2	IR5.0 v2 ASIMOV Project Handbook	5	TNO	CO		18.11.2021
IR5.1.3	IR5.1 ASIMOV – Project Handbook-living document	5	TNO	CO		16.05.2024
IR5.2.1	Exploitation Plan and Report	5	PU	TNO		22.06.2022
IR5.2.2	Exploitation Plan and Report	5	PU	TNO		18.06.2023
IR5.2.3	Exploitation Plan and Report	5	PU	TNO		10.05.2024
IR5.3.1	Dissemination Plan and Report	5	PU	TNO		22.06.2022
IR5.3.2	Dissemination Plan and Report	5	PU	TNO		25.07.2023
IR5.3.3	Dissemination Plan and Report	5	PU	TNO		25.04.2024
IR5.4.1	Key Performance Indicator Report	5	CO	TNO		10.05.2024